

# Cross-Language Speech Retrieval and its Evaluation in the Malach Project

Pavel Pecina

[pecina@ufal.mff.cuni.cz](mailto:pecina@ufal.mff.cuni.cz)

Institute of Formal and Applied Linguistics  
Charles University, Prague



Seminář formální lingvistiky  
ÚFAL, 20. 11. 2006

# Cross-Language Speech Retrieval and its Evaluation

# Cross-Language Speech **Retrieval** and its Evaluation

## Information Retrieval

- ▶ searching for information in documents or for documents themselves
- ▶ searching a body of information for objects that match a search query
- ▶ the science and practice of identification and efficient use of recorded data

# Cross-Language Speech Retrieval and its Evaluation

## Information Retrieval

- ▶ searching for information in documents or for documents themselves
- ▶ searching a body of information for objects that match a search query
- ▶ the science and practice of identification and efficient use of recorded data

## Speech Retrieval

- ▶ a special case of IR in which the information is in spoken form

# Cross-Language Speech Retrieval and its Evaluation

## Information Retrieval

- ▶ searching for information in documents or for documents themselves
- ▶ searching a body of information for objects that match a search query
- ▶ the science and practice of identification and efficient use of recorded data

## Speech Retrieval

- ▶ a special case of IR in which the information is in spoken form

## Cross-Language

- ▶ retrieving information in a language different from the language of the user's query

# Cross-Language Speech Retrieval and its Evaluation

## Information Retrieval

- ▶ searching for information in documents or for documents themselves
- ▶ searching a body of information for objects that match a search query
- ▶ the science and practice of identification and efficient use of recorded data

## Speech Retrieval

- ▶ a special case of IR in which the information is in spoken form

## Cross-Language

- ▶ retrieving information in a language different from the language of the user's query

## Evaluation

- ▶ deals with effectiveness of IR systems: how well they perform
- ▶ measures how well users are able to acquire information
- ▶ usually comparative: ranks a better system ahead of a worse system


# Roadmap

1. Introduction
2. Project Overview
  - ▶ *History*
  - ▶ *Tasks and Goals*
3. Speech Recognition
  - ▶ *Challenges and Results*
  - ▶ *Demo*
4. Speech Retrieval
  - ▶ Overview
5. Evaluation
  - ▶ *Test Collection*
  - ▶ *Evaluation Measures*
  - ▶ *CLEF 2006*
6. Conclusions


# Project Overview

# The story begins in 1993

The story begins in 1993 with a movie



## The story begins in 1993 with a movie and a vision



### Steven Spielberg's vision of:

1. collecting and preserving survivor and witness testimony of the Holocaust
2. cataloging those testimonies to make them available
3. disseminating the testimonies for educational purposes to fight intolerance
4. enabling others to collect testimonies of other atrocities and historical events or perhaps do so itself

## A brief history of the project

1993 Stephen Spielberg releases **Schindler's List**.

*He is approached by survivors who want him to listen their stories of Holocaust.*

1994 Spielberg starts **Survivors of the Shoah Visual History Foundation**  
*to videotape and preserve testimonies of Holocaust survivors and witnesses.*

1999 VHF assembled **the world's largest archive** of videotaped oral histories  
*with interviews from 52,000 survivors, liberators, and rescuers from 57 countries.*

2000 10% interviews **manually catalogized** by VHF at a cost of \$8 million.  
*One single testimony consumes an average of 35 hrs (index, summary, review).*

2001 **NSF project** proposal with the goal to dramatically improve access to large multilingual spoken word collections. *Principal investigators: UMD, JHU, IBM*

2001 Grant awarded; project **Multilingual Access to Large Spoken Archives** launches  
*\$7.5 million budget distributed over five years, CU and UWB part of the team.*

# The archive

- ▶ maintained by Visual History Foundation/Institute
- ▶ assembled in 1994–1999 by 2,300 interviewers and 1,000 photographers
- ▶ contains testimonies of 52,000 survivors from 57 countries in 32 languages
- ▶ total of 116,000 hours of VHS tapes, 180 TB of MPEG-1 digitalized video
- ▶ average duration of a testimony 2:15 hours, total cost per interview \$2,000
- ▶ extensive human cataloging completed for over 3,000 interviews (72 mil words)
- ▶ manually indexed (time-aligned descriptors from a 30,000-keyword thesaurus)



# The archive

- ▶ maintained by Visual History Foundation/Institute
- ▶ assembled in 1994–1999 by 2,300 interviewers and 1,000 photographers
- ▶ contains testimonies of 52,000 survivors from 57 countries in 32 languages
- ▶ total of 116,000 hours of VHS tapes, 180 TB of MPEG-1 digitalized video
- ▶ average duration of a testimony 2:15 hours, total cost per interview \$2,000
- ▶ extensive human cataloging completed for over 3,000 interviews (72 mil words)
- ▶ manually indexed (time-aligned descriptors from a 30,000-keyword thesaurus)
  
- ▶ 573 interviews recorded in the Czech Republic by 38 interviewers
- ▶ 4 500 testimonies provided by people born in the Czech Republic



# Full-description cataloging and annotations

## Interview-level annotation

- ▶ pre-interview questionnaire
- ▶ names of people and places mentioned in the course of
- ▶ free text summary an interview

## Segment-level annotation

- ▶ topic boundaries (average 3 min/segment)
- ▶ descriptions: *summary, cataloguer's scratchpad*
- ▶ thesaurus labels: *names, topic, locations, time periods*

	Location-Time	Concept	People
	Berlin 1939	Employment	Josef Stein
	Berlin 1939	Family life	Gretchen Stein Anna Stein
	Dresden 1939	Relocation Transportation-rail	
	Dresden 1939	Schooling	Gunter Wendt Maria

# “Real-time” cataloging and annotations

## Interview-level annotation

- ▶ pre-interview questionnaire

## Time-aligned annotation

- ▶ thesaurus labels: *names, concepts, locations, time periods*

Location–Time	Concept	People
 Berlin 1939	Employment	Josef Stein
	Family life	Gretchen Stein
		Anna Stein
 Dresden 1939	Relocation Transportation–rail	
	Schooling	Gunter Wendt Maria

# Cataloging interface

Current Timecode: 01:01:09:12 Cursor Timecode 01:33:36:00 1X



Notes  
Joe

New Keyword

Keywords for this Segment Type

K  Th  Ty

KW Hierarchy

- > academic life (CONTAINER ONLY) Miscellanec
- > cultural and social life (CONTAINER C cultural and
- > discrimination and intolerance (CONT Miscellanec
- > economic life (CONTAINER ONLY) Miscellanec
- > family life family life
- > food and eating (CONTAINER ONLY) food and dri
- > forced labor experience (CONTAINER Miscellanec
- > government and political life (CONTAINER Miscellanec

Save Segment Seg reset  Track Video


Notes	Start	End	Keywords
1	01:00:00:00	01:01:00:00	Wisnicz Nowy
2	01:01:00:00	01:02:00:00	
3	01:02:00:00	01:03:00:00	
4	01:03:00:00	01:04:00:00	
5	01:04:00:00	01:05:00:00	
6	01:05:00:00	01:06:00:00	Jewish identity
7	01:06:00:00	01:07:00:00	
8	01:07:00:00	01:08:00:00	
9	01:08:00:00	01:09:00:00	antisemitism
10	01:09:00:00	01:10:00:00	

People

All People	Name
Interviewee	Joe
fathers	Elias
mothers	Zisel
sisters	Dora
sisters	Miriam
brothers	Pearl
brothers	Salomon
wives	Sam
sons	Yadzia
	Harry


# Interview languages (top 20)

interview counts	
English	24,872
Russian	7,052
Hebrew	6,126
French	1,875
Polish	1,549
Spanish	1,352
Dutch	1,077
Hungarian	1,038
German	686
Bulgarian	645
Slovak	583
Czech	573
Portuguese	562
Yiddish	527
Italian	433
Serbian	382
Croatian	353
Ukrainian	320
Greek	301
Swedish	266



# Interview languages (top 20)

interview counts	
English	24,872
Russian	7,052
Hebrew	6,126
French	1,875
Polish	1,549
Spanish	1,352
Dutch	1,077
Hungarian	1,038
German	686
Bulgarian	645
Slovak	583
Czech	573
Portuguese	562
Yiddish	527
Italian	433
Serbian	382
Croatian	353
Ukrainian	320
Greek	301
Swedish	266



## Project tasks and participants

1. automatic recognition of spontaneous speech (multi-lingual)
2. machine supported translation of domain specific thesaurus
3. automatic topic boundary tagging and time-aligned metadata assignment
4. environment for cross-language information retrieval and browsing



IBM T.J. Watson Center, New York  
- *speech recognition in English*



Center for Speech and Language Processing, JHU, Baltimore  
- *speech recognition in other languages*  
- *Czech and other Slavic languages subcontracted to CU and UWB*



University of Maryland, College Park  
- *archive browsing, information retrieval and its evaluation*  
- *Czech test collection subcontracted to Charles University*

# Speech Recognition

## Project challenges

- ▶ complete speaker independent recognition of spontaneous speech
- ▶ relatively high technical quality of recordings
- ▶ low “language quality”: difficult even for a human listener:

- ▶ spontaneous, emotional, disfluent, and whispered speech from elders
- ▶ speech with background noise and frequent interruptions
- ▶ heavily accented speech that switches between languages
- ▶ speech with words such as names, obscure locations, unknown events

## Project challenges

- ▶ complete speaker independent recognition of spontaneous speech
- ▶ relatively high technical quality of recordings
- ▶ low “language quality”: difficult even for a human listener:

- ▶ spontaneous, emotional, disfluent, and whispered speech from elders
- ▶ speech with background noise and frequent interruptions
- ▶ heavily accented speech that switches between languages
- ▶ speech with words such as names, obscure locations, unknown events

- ▶ specific issue in Czech: **colloquial expressions and pronunciation**

oběd

[*o b j e d*]

[*o b j e t*]

[*v o b j e d*]

[*v o b j e t*]

Osvětim

[*o s v j e t i m*]

[*v o s v j e t i m*]

[*o s v j e n č i m*]

[*o z v j e t i m*]

## Speech recognition results

Word error rate estimated on a sample of manually transcribed data as a ratio of misrecognized words.

language	WER (%)
English	25.0
Czech	35.0
Russian	45.7
Slovak	34.5

# Speech recognition results

Word error rate estimated on a sample of manually transcribed data as a ratio of misrecognized words.

language	WER (%)
English	25.0
Czech	35.0
Russian	45.7
Slovak	34.5

## Manual transcriptions

language	TrData (h)
English	200
Czech	84
Russian	100
Slovak	


# Speech recognition results

Word error rate estimated on a sample of manually transcribed data as a ratio of misrecognized words.

language	WER (%)
English	25.0
Czech	35.0
Russian	45.7
Slovak	34.5

## Manual transcriptions

language	TrData (h)
English	200
Czech	84
Russian	100
Slovak	



# Speech recognition demo

name: \*\*\*

day of birth: Dec 26, 1924

country: Czechoslovakia

religion: judaism

keywords: hiding/death marches  
underground/resistance



Pane Pavle, začal jste historku o srncích a tatínkovi bez hvězdy. Jak to pokračovalo? Bylo, pokračovalo to tím způsobem, že tatínek si sundal hvězdu, pan doktor Jeřáb mu napsali skupinku na Kladně. To bylo báječný doktor, ten a fandila. Náš tatínek se vydal na cestu na Křivoklátsko, aby upekla že sem se Pochopitelně, že strejda Prošek s tím nechtěl nic mít. Za to byly krutý tresty, za to se tenkrát popravovalo. Takže strejda Prošek nepytlačil a bál se. Tady všude v lesích byli Němci. Střílelo se ... a náš táta se vydal na tuhle cestu a ubytoval se mnou slůvko toho v roce sem opravdu podařilo u pytlačit – za pomocí legendární a volal na. To byl pes – vlčák, s kterém dříve Prošek nepytlačil, a ten prostě každého sem se nepytlačil ...

# Speech recognition demo

name: \*\*\*

day of birth: Dec 26, 1924

country: Czechoslovakia

religion: judaism

keywords: hiding/death marches  
underground/resistance



Pane Pavle, začal jste historku o srncích a tatínkovi bez hvězdy. Jak to pokračovalo? Bylo, pokračovalo to tím způsobem, že tatínek si sundal hvězdu, pan doktor Jeřáb mu napsali skupinku na Kladně. To bylo báječný doktor, ten a fandila. Náš tatínek se vydal na cestu na Křivoklátsko, aby upekla že sem se Pochopitelně, že strejda Prošek s tím nechtěl nic mít. Za to byly krutý tresty, za to se tenkrát popravovalo. Takže strejda Prošek nepytlačil a bál se. Tady všude v lesích byli Němci. Střílelo se ... a náš táta se vydal na tuhle cestu a ubytoval se mnou slůvko toho v roce sem opravdu podařilo u pytlačit – za pomocí legendární a volal na. To byl pes – vlčák, s kterém dříve Prošek nepytlačil, a ten prostě každého sem se nepytlačil ...

# Speech recognition demo

name: \*\*\*

day of birth: Dec 26, 1924

country: Czechoslovakia

religion: judaism

keywords: hiding/death marches  
underground/resistance



Pane Pavle, začal jste historku o srncích a tatínkovi bez hvězdy. Jak to pokračovalo? Bylo, pokračovalo to tím způsobem, že tatínek si sundal hvězdu, pan doktor Jeřáb mu napsali skupinku na Kladně. To bylo báječný doktor, ten a fandila. Náš tatínek se vydal na cestu na Křivoklátsko, aby upekla že sem se Pochopitelně, že strejda Prošek s tím nechtěl nic mít. Za to byly krutý tresty, za to se tenkrát popravovalo. Takže strejda Prošek nepytlačil a bál se. Tady všude v lesích byli Němci. Střílelo se ... a náš táta se vydal na tuhle cestu a ubytoval se mnou slůvko toho v roce sem opravdu podařilo u pytlačit – za pomocí legendární a volal na. To byl pes – vlčák, s kterém dříve Prošek nepytlačil, a ten prostě každého sem se nepytlačil ...

# Speech recognition demo


name: \*\*\*

day of birth: Dec 26, 1924

country: Czechoslovakia

religion: judaism

keywords: hiding/death marches  
underground/resistance



Pane Pavle, začal jste historku o srncích a tatínkovi bez hvězdy. Jak to pokračovalo? Bylo, pokračovalo to tím způsobem, že tatínek si sundal hvězdu, pan doktor Jeřáb mu napsali skupinku na Kladně. To bylo báječný doktor, ten a fandila. Náš tatínek se vydal na cestu na Křivoklátsko, aby upekla že sem se Pochopitelně, že strejda Prošek s tím nechtěl nic mít. Za to byly krutý tresty, za to se tenkrát popravovalo. Takže strejda Prošek nepytlačil a bál se. Tady všude v lesích byli Němci. Střílelo se ... a náš táta se vydal na tuhle cestu a ubytoval se mnou slůvko toho v roce sem opravdu podařilo u pytlačit – za pomocí legendární a volal na. To byl pes – vlčák, s kterém dříve Prošek nepytlačil, a ten prostě každého sem se nepytlačil ...

# Speech recognition demo


name: \*\*\*

day of birth: Dec 26, 1924

country: Czechoslovakia

religion: judaism

keywords: hiding/death marches  
underground/resistance



Pane Pavle, začal jste historku o srncích a tatínkovi bez hvězdy. Jak to pokračovalo? Bylo, pokračovalo to tím způsobem, že tatínek si sundal hvězdu, pan doktor Jeřáb mu napsali skupinku na Kladně. To bylo báječný doktor, ten a fandila. Náš tatínek se vydal na cestu na Křivoklátsko, aby upekla že sem se Pochopitelně, že strejda Prošek s tím nechtěl nic mít. Za to byly krutý tresty, za to se tenkrát popravovalo. Takže strejda Prošek nepytlačil a bál se. Tady všude v lesích byli Němci. Střílelo se ... a náš táta se vydal na tuhle cestu a ubytoval se mnou slůvko toho v roce sem opravdu podařilo u pytlačit – za pomocí legendární a volal na. To byl pes – vlčák, s kterém dříve Prošek nepytlačil, a ten prostě každého sem se nepytlačil ...

# Speech recognition demo

name: \*\*\*

day of birth: Dec 26, 1924

country: Czechoslovakia

religion: judaism

keywords: hiding/death marches  
underground/resistance



Pane Pavle, začal jste historku o srncích a tatínkovi bez hvězdy. Jak to pokračovalo? Bylo, pokračovalo to tím způsobem, že tatínek si sundal hvězdu, pan doktor Jeřáb mu napsali skupinku na Kladně. To bylo báječný doktor, ten a fandila. Náš tatínek se vydal na cestu na Křivoklátsko, aby upekla že sem se Pochopitelně, že strejda Prošek s tím nechtěl nic mít. Za to byly krutý tresty, za to se tenkrát popravovalo. Takže strejda Prošek nepytlačil a bál se. Tady všude v lesích byli Němci. Střílelo se ... a náš táta se vydal na tuhle cestu a ubytoval se mnou slůvko toho v roce sem opravdu podařilo u pytlačit – za pomocí legendární a volal na. To byl pes – vlčák, s kterém dříve Prošek nepytlačil, a ten prostě každého sem se nepytlačil ...

# Speech recognition demo

name: \*\*\*

day of birth: Dec 26, 1924

country: Czechoslovakia

religion: judaism

keywords: hiding/death marches  
underground/resistance



Pane Pavle, začal jste historku o srncích a tatínkovi bez hvězdy. Jak to pokračovalo? Bylo, pokračovalo to tím způsobem, že tatínek si sundal hvězdu, pan doktor Jeřáb mu napsali skupinku na Kladně. To bylo báječný doktor, ten a fandila. Náš tatínek se vydal na cestu na Křivoklátsko, aby upekla že sem se Pochopitelně, že strejda Prošek s tím nechtěl nic mít. Za to byly krutý tresty, za to se tenkrát popravovalo. Takže strejda Prošek nepytlačil a bál se. Tady všude v lesích byli Němci. Střílelo se ... a náš táta se vydal na tuhle cestu a ubytoval se mnou slůvko toho v roce sem opravdu podařilo u pytlačit – za pomocí legendární a volal na. To byl pes – vlčák, s kterém dříve Prošek nepytlačil, a ten prostě každého sem se nepytlačil ...

# Speech recognition demo

name: \*\*\*

day of birth: Dec 26, 1924

country: Czechoslovakia

religion: judaism

keywords: hiding/death marches  
underground/resistance



Pane Pavle, začal jste historku o srncích a tatínkovi bez hvězdy. Jak to pokračovalo? Bylo, pokračovalo to tím způsobem, že tatínek si sundal hvězdu, pan doktor Jeřáb mu napsali skupinku na Kladně. To bylo báječný doktor, ten a fandila. Náš tatínek se vydal na cestu na Křivoklátsko, aby upekla že sem se Pochopitelně, že strejda Prošek s tím nechtěl nic mít. Za to byly krutý tresty, za to se tenkrát popravovalo. Takže strejda Prošek nepytlačil a bál se. Tady všude v lesích byli Němci. Střílelo se ... a náš táta se vydal na tuhle cestu a ubytoval se mnou slůvko toho v roce sem opravdu podařilo u pytlačit – za pomocí legendární a volal na. To byl pes – vlčák, s kterém dříve Prošek nepytlačil, a ten prostě každého sem se nepytlačil ...

# Speech recognition demo

name: \*\*\*

day of birth: Dec 26, 1924

country: Czechoslovakia

religion: judaism

keywords: hiding/death marches  
underground/resistance



Pane Pavle, začal jste historku o srncích a tatínkovi bez hvězdy. Jak to pokračovalo? Bylo, pokračovalo to tím způsobem, že tatínek si sundal hvězdu, pan doktor Jeřáb mu napsali skupinku na Kladně. To bylo báječný doktor, ten a fandila. Náš tatínek se vydal na cestu na Křivoklátsko, aby upekla že sem se Pochopitelně, že strejda Prošek s tím nechtěl nic mít. Za to byly krutý tresty, za to se tenkrát popravovalo. Takže strejda Prošek nepytlačil a bál se. Tady všude v lesích byli Němci. Střílelo se ... a náš táta se vydal na tuhle cestu a ubytoval se mňou slůvko toho v roce sem opravdu podařilo u pytlačit – za pomocí legendární a volal na. To byl pes – vlčák, s kterým dříve Prošek nepytlačil, a ten prostě každého sem se nepytlačil ...

# Speech recognition demo


name: \*\*\*

day of birth: Dec 26, 1924

country: Czechoslovakia

religion: judaism

keywords: hiding/death marches  
underground/resistance



Pane Pavle, začal jste historku o srncích a tatínkovi bez hvězdy. Jak to pokračovalo? Bylo, pokračovalo to tím způsobem, že tatínek si sundal hvězdu, pan doktor Jeřáb mu napsali skupinku na Kladně. To bylo báječný doktor, ten a fandila. Náš tatínek se vydal na cestu na Křivoklátsko, aby upekla že sem se Pochopitelně, že strejda Prošek s tím nechtěl nic mít. Za to byly krutý tresty, za to se tenkrát popravovalo. Takže strejda Prošek nepytlačil a bál se. Tady všude v lesích byli Němci. Střílelo se ... a náš táta se vydal na tuhle cestu a ubytoval se mnoou slůvko toho v roce sem opravdu podařilo u pytlačit – za pomoci legendární a volal na. To byl pes – vlčák, s kterém dříve Prošek nepytlačil, a ten prostě každého sem se nepytlačil ...

# Speech recognition demo

name: \* \* \*

day of birth: Dec 26, 1924

country: Czechoslovakia

religion: judaism

keywords: hiding/death marches  
underground/resistance



Pane Pavle, začal jste historku o srncích a tatínkovi bez hvězdy. Jak to pokračovalo? Bylo, pokračovalo to tím způsobem, že tatínek si sundal hvězdu, pan doktor Jeřáb mu napsali skupinku na Kladně. To bylo báječný doktor, ten a fandila. Náš tatínek se vydal na cestu na Křivoklátsko, aby upekla že sem se Pochopitelně, že strejda Prošek s tím nechtěl nic mít. Za to byly krutý tresty, za to se tenkrát popravovalo. Takže strejda Prošek nepytlačil a bál se. Tady všude v lesích byli Němci. Střílelo se ... a náš táta se vydal na tuhle cestu a ubytoval se mno slůvko toho v roce sem opravdu podařilo u pytlačit – za pomoci legendární a volal na. To byl pes – vlčák, s kterém dříve Prošek nepytlačil, a ten prostě každého sem se nepytlačil ...

# Speech recognition demo

name: \* \* \*

day of birth: Dec 26, 1924

country: Czechoslovakia

religion: judaism

keywords: hiding/death marches  
underground/resistance



Pane Pavle, začal jste historku o srncích a tatínkovi bez hvězdy. Jak to pokračovalo? Bylo, pokračovalo to tím způsobem, že tatínek si sundal hvězdu, pan doktor Jeřáb mu napsali skupinku na Kladně. To bylo báječný doktor, ten a fandila. Náš tatínek se vydal na cestu na Křivoklátsko, aby upekla že sem se Pochopitelně, že strejda Prošek s tím nechtěl nic mít. Za to byly krutý tresty, za to se tenkrát popravovalo. Takže strejda Prošek nepytlačil a bál se. Tady všude v lesích byli Němci. Střílelo se ... a náš táta se vydal na tuhle cestu a ubytoval se mno slůvko toho v roce sem opravdu podařilo u pytlačit – za pomocí legendární a volal na. To byl pes – vlčák, s kterém dříve Prošek nepytlačil, a ten prostě každého sem se nepytlačil ...

# Speech recognition demo

name: \*\*\*

day of birth: Dec 26, 1924

country: Czechoslovakia

religion: judaism

keywords: hiding/death marches  
underground/resistance



pane pavle začal jste historku o srncích a tatínkovi bez hvězdy jak to pokračovalo bylo pokračovalo to tím způsobem že tatínek si sundal hvězdu pan doktor jeřáb mu napsali skupinku na kladně to bylo báječný doktor ten a fandila náš tatínek se vydal na cestu na křivoklátsko aby upekla že sem se ... pochopitelně že strejda prošek s tím nechtěl nic mít za to byly krutý tresty za to se tenkrát popravovalo takže strejda prošek nepytlačil a bál se tady všude v lesích byli němci střílelo se ... a náš táta se vydal na tuhle cestu a ubytoval se mnou slůvko toho v roce sem opravdu podařilo u pytlačit – za pomocí legendární a volal na to byl pes vlčák s kterém dříve prošek nepytlačil a ten prostě každého sem se nepytlačil ...

# Speech recognition demo


name: Hugo Pavel

day of birth: Dec 26, 1924

country: Czechoslovakia

religion: judaism

keywords: hiding/death marches  
underground/resistance



pane pavle začal jste historku o srncích a tatínkovi bez hvězdy jak to pokračovalo bylo pokračovalo to tím způsobem že tatínek si sundal hvězdu pan doktor jeřáb mu napsali skupinku na kladně to bylo báječný doktor ten a fandila náš tatínek se vydal na cestu na křivoklátsko aby upekla že sem se ... pochopitelně že strejda prošek s tím nechtěl nic mít za to byly krutý tresty za to se tenkrát popravovalo takže strejda prošek nepytlačil a bál se tady všude v lesích byli němci střílelo se ... a náš táta se vydal na tuhle cestu a ubytoval se mnou slůvko toho v roce sem opravdu podařilo u pytlačit – za pomocí legendární a volal na to byl pes vlčák s kterém dříve prošek nepytlačil a ten prostě každého sem se nepytlačil ...

# Information Retrieval

## Bag-of-words representation

- ▶ Simple strategy for representing documents
- ▶ Count how many times each word occurs (regardless of word order)
- ▶ Distribution over fixed vocabulary

# Bag-of-words representation

- ▶ Simple strategy for representing documents
- ▶ Count how many times each word occurs (regardless of word order)
- ▶ Distribution over fixed vocabulary

document  $d_1$

Indonesia started a  
huge security  
operation ahead of  
the arrival of  
President Bush

document  $d_2$

British Prime  
Minister Tony Blair  
flew to Afghanistan  
on Monday

# Bag-of-words representation

- ▶ Simple strategy for representing documents
- ▶ Count how many times each word occurs (regardless of word order)
- ▶ Distribution over fixed vocabulary

document $d_1$
Indonesia started a huge security operation ahead of the arrival of President Bush

document $d_2$
British Prime Minister Tony Blair flew to Afghanistan on Monday

word	$d_1$
a	1
Afghanistan	0
ahead	1
arrival	1
Blair	0
British	0
Bush	1
flew	0
huge	1
Indonesia	1
Minister	0
Monday	0
of	1
on	0
operation	1
President	1
Prime	0
security	1
started	1
the	1
to	0
Tony	0

# Bag-of-words representation

- ▶ Simple strategy for representing documents
- ▶ Count how many times each word occurs (regardless of word order)
- ▶ Distribution over fixed vocabulary

document  $d_1$

Indonesia started a  
huge security  
operation ahead of  
the arrival of  
President Bush

document  $d_2$

British Prime  
Minister Tony Blair  
flew to Afghanistan  
on Monday

word	$d_1$	$d_2$
a	1	0
Afghanistan	0	1
ahead	1	0
arrival	1	0
Blair	0	1
British	0	1
Bush	1	0
flew	0	1
huge	1	0
Indonesia	1	0
Minister	0	1
Monday	0	1
of	1	0
on	0	1
operation	1	0
President	1	0
Prime	0	1
security	1	0
started	1	0
the	1	0
to	0	1
Tony	0	1

# Bag-of-words representation / Vector space model

- ▶ Simple strategy for representing documents
- ▶ Count how many times each word occurs (regardless of word order)
- ▶ Distribution over fixed vocabulary


**document  $d_1$**

Indonesia started a  
huge security  
operation ahead of  
the arrival of  
President Bush

**document  $d_2$**

British Prime  
Minister Tony Blair  
flew to Afghanistan  
on Monday

word	$d_1$	$d_2$
a	1	0
Afghanistan	0	1
ahead	1	0
arrival	1	0
Blair	0	1
British	0	1
Bush	1	0
flew	0	1
huge	1	0
Indonesia	1	0
Minister	0	1
Monday	0	1
of	1	0
on	0	1
operation	1	0
President	1	0
Prime	0	1
security	1	0
started	1	0
the	1	0
to	0	1
Tony	0	1



# Bag-of-words representation / Vector space model

- ▶ Simple strategy for representing documents
- ▶ Count how many times each word occurs (regardless of word order)
- ▶ Distribution over fixed vocabulary


document  $d_1$

Indonesia started a  
huge security  
operation ahead of  
the arrival of  
President Bush

document  $d_2$

British Prime  
Minister Tony Blair  
flew to Afghanistan  
on Monday

word	$d_1$	$d_2$
a	1	0
Afghanistan	0	1
ahead	1	0
arrival	1	0
Blair	0	1
British	0	1
Bush	1	0
flew	0	1
huge	1	0
Indonesia	1	0
Minister	0	1
Monday	0	1
of	1	0
on	0	1
operation	1	0
President	1	0
Prime	0	1
security	1	0
started	1	0
the	1	0
to	0	1
Tony	0	1



# Bag-of-words representation / Vector space model

- ▶ Simple strategy for representing documents
- ▶ Count how many times each word occurs (regardless of word order)
- ▶ Distribution over fixed vocabulary


**document  $d_1$**

Indonesia started a  
huge security  
operation ahead of  
the arrival of  
President Bush

**document  $d_2$**

British Prime  
Minister Tony Blair  
flew to Afghanistan  
on Monday

word	$d_1$	$d_2$
a	1	0
Afghanistan	0	1
ahead	1	0
arrival	1	0
Blair	0	1
British	0	1
Bush	1	0
flew	0	1
huge	1	0
Indonesia	1	0
Minister	0	1
Monday	0	1
of	1	0
on	0	1
operation	1	0
President	1	0
Prime	0	1
security	1	0
started	1	0
the	1	0
to	0	1
Tony	0	1



## Similarity-based ranking

1. Treat the query as if it were a document: *create a query bag-of-terms*
2. Find the similarity of each document: *compute inner product*
3. Rank order the documents by similarity: *most similar to the query first*

# Similarity-based ranking

1. Treat the query as if it were a document: *create a query bag-of-terms*
2. Find the similarity of each document: *compute inner product*
3. Rank order the documents by similarity: *most similar to the query first*

document  $d_1$

Indonesia started a  
huge security  
operation ahead of  
the arrival of  
President Bush

document  $d_2$

British Prime  
Minister Tony Blair  
flew to Afghanistan  
on Monday

query

Prime Minister

# Similarity-based ranking

1. Treat the query as if it were a document: *create a query bag-of-terms*
2. Find the similarity of each document: *compute inner product*
3. Rank order the documents by similarity: *most similar to the query first*

**document  $d_1$**

Indonesia started a  
huge security  
operation ahead of  
the arrival of  
President Bush


**document  $d_2$**

British Prime  
Minister Tony Blair  
flew to Afghanistan  
on Monday

**query**

Prime Minister

word	$d_1$	$d_2$
a	1	0
Afghanistan	0	1
ahead	1	0
arrival	1	0
Blair	0	1
British	0	1
Bush	1	0
flew	0	1
huge	1	0
Indonesia	1	0
Minister	0	1
Monday	0	1
of	1	0
on	0	1
operation	1	0
President	1	0
Prime	0	1
security	1	0
started	1	0
the	1	0
to	0	1
Tony	0	1



# Similarity-based ranking

1. Treat the query as if it were a document: *create a query bag-of-terms*
2. Find the similarity of each document: *compute inner product*
3. Rank order the documents by similarity: *most similar to the query first*

**document  $d_1$**

Indonesia started a  
huge security  
operation ahead of  
the arrival of  
President Bush


**document  $d_2$**

British Prime  
Minister Tony Blair  
flew to Afghanistan  
on Monday

**query**

Prime Minister

word	$d_1$	$d_2$	$q$
a	1	0	0
Afghanistan	0	1	0
ahead	1	0	0
arrival	1	0	0
Blair	0	1	0
British	0	1	0
Bush	1	0	0
flew	0	1	0
huge	1	0	0
Indonesia	1	0	0
Minister	0	1	1
Monday	0	1	0
of	1	0	0
on	0	1	0
operation	1	0	0
President	1	0	0
Prime	0	1	1
security	1	0	0
started	1	0	0
the	1	0	0
to	0	1	0
Tony	0	1	0



# Similarity-based ranking

1. Treat the query as if it were a document: *create a query bag-of-terms*
2. Find the similarity of each document: *compute inner product*
3. Rank order the documents by similarity: *most similar to the query first*

**document  $d_1$**

Indonesia started a  
huge security  
operation ahead of  
the arrival of  
President Bush


**document  $d_2$**

British Prime  
Minister Tony Blair  
flew to Afghanistan  
on Monday

**query**

Prime Minister

word	$d_1$	$d_2$	$q$
a	1	0	0
Afghanistan	0	1	0
ahead	1	0	0
arrival	1	0	0
Blair	0	1	0
British	0	1	0
Bush	1	0	0
flew	0	1	0
huge	1	0	0
Indonesia	1	0	0
Minister	0	1	1
Monday	0	1	0
of	1	0	0
on	0	1	0
operation	1	0	0
President	1	0	0
Prime	0	1	1
security	1	0	0
started	1	0	0
the	1	0	0
to	0	1	0
Tony	0	1	0



# Similarity-based ranking

1. Treat the query as if it were a document: *create a query bag-of-terms*
2. Find the similarity of each document: *compute inner product*
3. Rank order the documents by similarity: *most similar to the query first*

**document  $d_1$**

Indonesia started a huge security operation ahead of the arrival of President Bush


**document  $d_2$**

British Prime Minister Tony Blair flew to Afghanistan on Monday

**query**

Prime Minister

word	$d_1$	$d_2$	$q$
a	1	0	0
Afghanistan	0	1	0
ahead	1	0	0
arrival	1	0	0
Blair	0	1	0
British	0	1	0
Bush	1	0	0
flew	0	1	0
huge	1	0	0
Indonesia	1	0	0
Minister	0	1	1
Monday	0	1	0
of	1	0	0
on	0	1	0
operation	1	0	0
President	1	0	0
Prime	0	1	1
security	1	0	0
started	1	0	0
the	1	0	0
to	0	1	0
Tony	0	1	0



# What to use (and not use) as “words”?

## Substrings

- ▶ overlapping character n–grams

## Tokens

- ▶ white–space–delimited word forms

## Normalized forms

- ▶ lemmas, stems

## Shingles

- ▶ overlapping word n–grams

## Multiwords

- ▶ collocations, multiword lexemes

---

## Stopwords

- ▶ too frequent or too rare words
- ▶ closed–class words (*prepositions, conjunctions, etc.*)

## Query expansion

Finds terms that could have been in the query

- ▶ synonyms
- ▶ other related terms

Blind relevance feedback is widely used

1. search once using the original query
2. find discriminating terms in top-ranked documents
3. add new query terms / reweight existing terms

Several alternative approaches

- ▶ thesaurus-based expansion
- ▶ collocations
- ▶ LSI

[Back to Speech Retrieval](#)

# Some key insights

## Speech Retrieval (recap)

- ▶ A special case of IR in which the information is in spoken form

# Some key insights

## Speech Retrieval (recap)

- ▶ A special case of IR in which the information is in spoken form

## Recognition and retrieval can be decomposed

- ▶ Build IR system on ASR output.

## Some key insights

### Speech Retrieval (recap)

- ▶ A special case of IR in which the information is in spoken form

### Recognition and retrieval can be decomposed

- ▶ Build IR system on ASR output.

### Retrieval is robust with recognition results

- ▶ Up to 40% word error rate is tolerable (*TREC result*)

## Some key insights

### Speech Retrieval (recap)

- ▶ A special case of IR in which the information is in spoken form

### Recognition and retrieval can be decomposed

- ▶ Build IR system on ASR output.

### Retrieval is robust with recognition results

- ▶ Up to 40% word error rate is tolerable (*TREC result*)

### Recognition errors may not bother the system, but they **do** bother the user

- ▶ Retrieval based on ASR output should return playback points.

## Some key insights

### Speech Retrieval (recap)

- ▶ A special case of IR in which the information is in spoken form

### Recognition and retrieval can be decomposed

- ▶ Build IR system on ASR output.

### Retrieval is robust with recognition results

- ▶ Up to 40% word error rate is tolerable (*TREC result*)


### Recognition errors may not bother the system, but they **do** bother the user

- ▶ Retrieval based on ASR output should return playback points.

### Segment-level indexing/summary is useful

- ▶ Vocabulary shift/pauses provide strong cues for boundary tagging

# System overview




# Document processing

## Speech



# Document processing

## Speech Transcription



# Document processing

Speech  
Transcription

Boundary Tagging



# Document processing

Speech  
Transcription

Boundary Tagging  
Content Tagging



Berlin 1939	Employment	Josef Stein
Berlin 1939	Family life	Gretchen Stein Anna Stein
Dresden 1939	Relocation Transportation-rail	
Dresden 1939	Schooling	Gunter Wendt Maria

# Document processing

Speech  
Transcription

Boundary Tagging  
Content Tagging

Document  
Representation



Berlin 1939	Employment	Josef Stein
Berlin 1939	Family life	Gretchen Stein Anna Stein
Dresden 1939	Relocation Transportation-rail	
Dresden 1939	Schooling	Gunter Wendt Maria



# Spoken document example

Passage from English interview with full annotation

doc no 00009-056150.002

interview data Sidonia L., 1930

name Issac L., Cyla L.

manual keyword family businesses, family life, food, Przemysl (Poland)

summary SL describes her parents and their roles in the family business. She remembers her home and she recalls her responsibilities. . .

asr text *were to tell us about that my mother's name was sell us c y l a new and her maiden name was leap shark l i e b b a c h a r d my mother was a dress . . .*

auto keyword *family businesses, family homes, means of adaptation and survival, extended family members . . .*

# Spoken document example

Passage from Czech interview with brief annotation

doc no 01539-025217.003

interview data Alois P., 1927

name -na-

manual keyword -na-

summary -na-

asr text *a když nějaká ta dívence na na a pláží svolávali Stalin že jo a nu náš fotograf přišel úplně sem byl strašně hrdý že se mě rozuměla a pak sem věděl takže se říká dva zešílení to je že na jedné kde už pak už bylo vše říkalo že venku koho jste si vzal jak jste se seznámili dobře zůstala v Polsku ...*

auto keyword -na-

# Evaluation

# Evaluation

Question:

- ▶ How well do we perform?

# Evaluation

Question:

- ▶ How well do we perform?

Criteria

- ▶ Effectiveness, efficiency, usability?

# Evaluation

Question:

- ▶ How well do we perform?

Criteria

- ▶ Effectiveness, efficiency, usability

# Evaluation

Question:

- ▶ How well do we perform?

Criteria

- ▶ Effectiveness, efficiency, usability

User-centered strategy

- ▶ Given several users and at least two retrieval systems
- ▶ Have each user try the same task on both systems
- ▶ Measure which system works the “best”

# Evaluation

Question:

- ▶ How well do we perform?

Criteria

- ▶ Effectiveness, efficiency, usability

User-centered strategy

- ▶ Given several users and at least two retrieval systems
- ▶ Have each user try the same task on both systems
- ▶ Measure which system works the “best”

System-centered strategy

- ▶ Given documents, queries, and relevance judgements
- ▶ Try several variations on the retrieval systems
- ▶ Measure which ranks more good docs near the top

# Evaluation

Question:

- ▶ How well do we perform?

Criteria

- ▶ Effectiveness, efficiency, usability

User-centered strategy

- ▶ Given several users and at least two retrieval systems
- ▶ Have each user try the same task on both systems
- ▶ Measure which system works the “best”

System-centered strategy

- ▶ Given documents, queries, and relevance judgements = test collection
- ▶ Try several variations on the retrieval systems
- ▶ Measure which ranks more good docs near the top

# Test collection design

## Documents

- ▶ Representative sources (*interviewees*)
- ▶ Representative topics (*stories*)

## Topics

- ▶ Detailed and structured description of actual information needs
- ▶ Used as a basis for query formulation

## Relevance judgements

- ▶ Document–topic relations (binary relevance)
- ▶ Created by humans, perpetually valid
- ▶ Sampled, focus on documents **likely be retrieved**

# Document collections (Malach)

## English

- ▶ 297 interviews
- ▶ known-boundary condition (segments)
- ▶ 8,104 topically-coherent segments
- ▶ average 503 words/segment
- ▶ ASR: 25% mean Word Error Rate

## Czech

- ▶ 350 interviews
- ▶ unknown segment boundaries
- ▶ 3-minute automatically generated passages, with 67% overlap
- ▶ start times used as DOCNO for easy results
- ▶ ASR: 35% mean Word Error Rate

*Distributed to track participants by ELDA*

## Topic construction

- ▶ 115 representative topics developed from **actual user requests**:
- ▶ Scholars, educators, documentary film makers, and others produced 250 topic-oriented written requests for materials from the collection.
- ▶ from English translated to *Czech, French, German, Spanish, and Dutch*
- ▶ TREC-like topic descriptions consists of *title*, a *short description* and a *narrative description*:

# Topic construction

- ▶ 115 representative topics developed from **actual user requests**:
- ▶ Scholars, educators, documentary film makers, and others produced 250 topic-oriented written requests for materials from the collection.
- ▶ from English translated to *Czech, French, German, Spanish, and Dutch*
- ▶ TREC-like topic descriptions consists of *title*, a *short description* and a *narrative description*:

num 1173

title **Dětské umění v Terezíně**

desc Hledáme popis uměleckých aktivit dětí v Terezíně, jako např. hudby, divadla, malování, poezie a jiných psaných děl.

narr *Relevantní materiál by měl obsahovat diskuse o těchto aktivitách a to, jak ovlivnily přečkání holokaustu a následný život dětí. Zejména jsou žádané příběhy, ve kterých účastník rozhovoru uvádí příklady takových aktivit.*

# Topic construction

- ▶ 115 representative topics developed from **actual user requests**:
- ▶ Scholars, educators, documentary film makers, and others produced 250 topic-oriented written requests for materials from the collection.
- ▶ from English translated to *Czech, French, German, Spanish, and Dutch*
- ▶ TREC-like topic descriptions consists of *title*, a *short description* and a *narrative description*:

num 1431

title **Denní život v Terezíně**

desc Popište denní život v táboře Terezín.

narr *Anekdoty, příběhy nebo detaily o denním životě v táboře. Relevantní jsou příběhy, které se zmiňují o modlitbách, svátcích, volném čase vězňů a strukturách vnitřní vlády v táborech.*

*Příběhy, které popisují neobvyklé události v životě vězňů, relevantní nejsou.*

# Topic construction

- ▶ 115 representative topics developed from **actual user requests**:
- ▶ Scholars, educators, documentary film makers, and others produced 250 topic-oriented written requests for materials from the collection.
- ▶ from English translated to *Czech, French, German, Spanish, and Dutch*
- ▶ TREC-like topic descriptions consists of *title*, a *short description* and a *narrative description*:

num 1431

title **Denní život v Terezíně**

desc Popište denní život v táboře Terezín.

narr *Anekdoty, příběhy nebo detaily o denním životě v táboře. Relevantní jsou příběhy, které se zmiňují o modlitbách, svátcích, volném čase vězňů a strukturách vnitřní vlády v táborech.*

*Příběhy, které popisují neobvyklé události v životě vězňů, relevantní nejsou.*

## Relevance assessment

A manual process to acquire relevance judgements for document–topic pairs.  
Ideally for **all** document–topic pairs – infeasible.

### Search guided relevance assessment

- ▶ for each topic a set of documents to be judged is restricted to those potentially relevant by full-text search
- ▶ *topic research → query formulation → search → judging*

### Highly ranked (pooled) relevance assessment

- ▶ Restriction based on results of actual evaluation runs
- ▶  $n$ -deep pools from  $m$ -systems

## Relevance assessment


A manual process to acquire relevance judgements for document–topic pairs.  
Ideally for **all** document–topic pairs – infeasible.

### Search guided relevance assessment

- ▶ for each topic a set of documents to be judged is restricted to those potentially relevant by full-text search
- ▶ *topic research → query formulation → search → judging*

### Highly ranked (pooled) relevance assessment

- ▶ Restriction based on results of actual evaluation runs
- ▶  $n$ -deep pools from  $m$ -systems



## Relevance assessment


A manual process to acquire relevance judgements for document–topic pairs.  
Ideally for **all** document–topic pairs – infeasible.

### Search guided relevance assessment

- ▶ for each topic a set of documents to be judged is restricted to those potentially relevant by full-text search
- ▶ *topic research → query formulation → search → judging*

### Highly ranked (pooled) relevance assessment

- ▶ Restriction based on results of actual evaluation runs
- ▶  $n$ -deep pools from  $m$ -systems



## Relevance assessment


A manual process to acquire relevance judgements for document–topic pairs.  
Ideally for **all** document–topic pairs – infeasible.

### Search guided relevance assessment

- ▶ for each topic a set of documents to be judged is restricted to those potentially relevant by full-text search
- ▶ *topic research → query formulation → search → judging*

### Highly ranked (pooled) relevance assessment

- ▶ Restriction based on results of actual evaluation runs
- ▶  $n$ -deep pools from  $m$ -systems



## Relevance assessment


A manual process to acquire relevance judgements for document–topic pairs.  
Ideally for **all** document–topic pairs – infeasible.

### Search guided relevance assessment

- ▶ for each topic a set of documents to be judged is restricted to those potentially relevant by full-text search
- ▶ *topic research → query formulation → search → judging*

### Highly ranked (pooled) relevance assessment

- ▶ Restriction based on results of actual evaluation runs
- ▶  $n$ -deep pools from  $m$ -systems



## Relevance categories

- |            |  |   |
|------------|--|---|
| Direct     | Direct evidence for what the user asks for<br><i>Talks about food given to Auschwitz inmates</i>   |  |
| Indirect   | Indirect evidence on the topic; data from which one could infer something about the topic<br><i>Talks about seeing emaciated people in Auschwitz</i>                       |  |
| Context    | Background/context for the topic; sets the stage for what the user asks for; sheds additional light on the topic<br><i>Talks about physical labor of Auschwitz inmates</i> |  |
| Comparison | Information on similar/parallel/contrasting situation<br><i>Talks about food in Warsaw ghetto</i>  |  |

## Relevance categories

Direct	Direct evidence for what the user asks for <i>Talks about food given to Auschwitz inmates</i>	
Indirect	Indirect evidence on the topic; data from which one could infer something about the topic <i>Talks about seeing emaciated people in Auschwitz</i>	
Context	Background/context for the topic; sets the stage for what the user asks for; sheds additional light on the topic <i>Talks about physical labor of Auschwitz inmates</i>	
Comparison	Information on similar/parallel/contrasting situation <i>Talks about food in Warsaw ghetto</i>	
Overall	Strictly from the point of view of finding out about the topic, how useful is this segment for the requester <i>Talks about food in Auschwitz</i>	

## Relevance categories

Direct	Direct evidence for what the user asks for <i>Talks about food given to Auschwitz inmates</i>	
Indirect	Indirect evidence on the topic; data from which one could infer something about the topic <i>Talks about seeing emaciated people in Auschwitz</i>	
Context	Background/context for the topic; sets the stage for what the user asks for; sheds additional light on the topic <i>Talks about physical labor of Auschwitz inmates</i>	
Comparison	Information on similar/parallel/contrasting situation <i>Talks about food in Warsaw ghetto</i>	
Overall	Strictly from the point of view of finding out about the topic, how useful is this segment for the requester <i>Talks about food in Auschwitz</i>	

- ▶ Five levels of relevance for each (0=none, 4=highly)
- ▶ Collapsed to binary relevance using  $\{\text{Direct} \geq 2\} \cup \{\text{Indirect} \geq 2\}$



File Help

Search Assessment

PIQ		Keyword		Transcript	Terezin	Exact match				
-----	--	---------	--	------------	---------	-------------	--	--	--	--



PIQ

Keyword

Transcript

Terezin

Exact match



196 interviews found. Displaying results 1-10

**Efim Markelis-Dominin (ID: 31115, 1 segment, 0 point(s) already marked for this topic)**

Locations: ...

Concepts: ...

**Kunhuta Buresova (ID: 14932, 3 segments, 0 point(s) already marked for this topic)**

Locations: ... Theresienstadt (Czechoslovakia : Ghetto), Czechoslovakia 1943, Czechoslovakia 1944 ...

Concepts: ... forced labor in the ghettos, means of adaptation and survival in the ghettos, forced labor: agriculture, stealing in the ghettos ...

**Alzbeta Bernatova (ID: 30796, 2 segments, 0 point(s) already marked for this topic)**

Locations: ... Czechoslovakia 1939 (Mar 15) - 1945 (May 9), Theresienstadt (Czechoslovakia : Ghetto) ...

Concepts: ... sharing food and drink in the ghettos, interaction with family members in the refugee camps ...

**Hugo Pavel (ID: 13135, 6 segments, 0 point(s) already marked for this topic)**

Locations: ... Theresienstadt (Czechoslovakia : Ghetto), Czechoslovakia 1943, Germany 1944, Germany 1945 (Jan 1 - May 7), ...

Concepts: ... housing conditions in the ghettos, food in the camps ...

**Hana Tvrzská (ID: 23005, 3 segments, 0 point(s) already marked for this topic)**

Locations: ... Czechoslovakia 1941, Czechoslovakia 1942, Protivín (Czechoslovakia) ...

Concepts: ... awareness of deportations and/or transfers ...

**Felice Kvapilova (ID: 23179, 2 segments, 0 point(s) already marked for this topic) - Hiding**

Locations: ...

Concepts: ...

**Eva Liskova (ID: 28592, 5 segments, 0 point(s) already marked for this topic) - Death Marches**

Locations: ...

Concepts: ... cultural and social activities in the ghettos, clandestine activities in the ghettos, Appell in the ghettos, deportations, means of transport, ...

**Margit Herrmannova (ID: 31114, 1 segment, 0 point(s) already marked for this topic)**

Locations: ...

Concepts: ...

**Anna Brynberg (ID: 13682, 1 segment, 0 point(s) already marked for this topic)**

Locations: ...

Concepts: ...

**Jiri Bures (ID: 20065, 3 segments, 0 point(s) already marked for this topic)**

Theresienstadt (Czechoslovakia : Ghetto), Czechoslovakia 1943

### Keyword



### Transcri

Contain



1

Germany 1944  
Germany 1945 (Jan 1 - May 7)  
Zossen-Wulkow bei Trebnitz (Germany  
Concentration Camp)  
food in the camps

nač my jíme bydlič a my jíme byly dobytovany nařízení po práci  
a tam už to bylo volně v zátoce výstaviště nemohlo být prostě první prostě prostě  
s tou svou otcem byl tam pokusím o útek zaplatili ty lidí život protože chytli  
také popravili to je docela známá věc že byli pověšeni ty kosti dělal šli do  
koncentráku takže s- pokud ale kde nebyl problém ani utekl z terezína když budeme od  
| pavlovi když to hildali četníci ty mladiství chodili na práci do zemědělství říkalo se  
tomu landwirtschaft to bylo za terezín žilo kolem terezína byl zelinářském poli pro terezín pro  
ss komandaturu takže nebyl problém otec terezína nebyl problém otec vulkova problém protože sem  
měl  
doma rodiče a ty si to odnesl v první řadě ... tady byla zodpovědnost vůči  
té rodině doufat ... ale nebyl problém ten spor že se tam mezi těma lidma  
udržet protože němci byli na stole prostě by vás udal jo zapálit ty otázky ...  
jak jste tam byli stravovali ... no tak stravovali žili jsme ovšem zažili jsme tam  
také strašný hlad ke konci o tom že jsme měli kůru ze stromu trávu se  
svou fotku tý se z kuchyně jsme vybíraly byla ta potom ke konci špatná doba  
chodili franta většinou potraviny z terezína takový ty tvrdý potraviny a brambory takový ty  
věci to zřejmě ty ... esesáci tě zde scházel tam takže to měl na starosti  
těch okolní vesnic od sedláčků to vypadalo že jo to bylo to byl kuchařem byla  
taková že v kuchyni a tom také pak vaření to byl v terezín takový to  
byly většinou tuřín spal to bylo celý vařil dost asi deset deka směli táborků ...  
filosof ještě pluku vyhodil nebo sem to vždycky okolo pak sem se ty ty šlupky  
vod docentovi jednou za týden byla buchta s takovým krémem my jsme tomu říkali takové  
to bylo kafe že jo jsme vždycky říkali až bude po válce se to buchuť  
udělal paninko to v životě dál potom korupci kupilli to bylo také takový ... prostě  
ze čtyřech letech opakovala ke konci to protože ke konci to dostala ke konci  
| to znamená ke konci když už potom by rok čtyřicet šátek roku čtyřicet pět  
tak už to bylo zlý protože z východu se ztratili rusové a došlo k tomu  
já bych chtěl ještě ráda ještě k tomu i já sem včera četl tady podrobili  
výslechu z toho že frances počkej rakousku tma toho teda se jmenoval že on říká  
že vůbec se tam nějak provinili tím ale vo tom strašně vězně mlátil ... já  
sem to už na floridu to jsme ještě jako nemluvili ale i tam sem byl  
u něj strašně bydlel tam byl rodině se ozývaly na těch lidí vše koho tři  
z těch prostě že na tu práci nedělal dobré ale byli lidí který byli placeny  
za den voskovc jakýmkoli to mlátil lidi otu rezka že ze zbraslavky z toho mlátili  
a oni mlátili tím potom také aby esesáci nemátili nevrátil | akorát voda a potom  
byl mezi námi jeden vězeň pracoval v lodži který také hildala ale ten jako fakt  
fackoval toho po válce popravy ale tenhle ten stužka ten prostě mlátil byl takový zámek

Germany 1944  
Germany 1945 (Jan 1 - May 7)  
Zossen-Wulkow bei Trebnitz (Germany  
Concentration Camp)  
**brutal treatment in the camps**  
**beatings**  
Stuschka, Franz



Theresienstadt (Czechoslovakia : Ghetto)  
 Czechoslovakia 1943  
 housing conditions in the ghettos

jako tato skupina která byla po tu dobu těch třech neděl v tom v těch  
 veletržních boudách tak i v terezíně jsme se potom scházeli pokud to bylo možný protože  
 podporu to nařízení že se nesmí říct že se mohou stýkat muži se ženami my  
 jsme tam měli také děvčata v našem věku takže jsme se potom ještě v tom  
 terezíně scházeli teda v tom terezíně jednak jak se ta ... do té no v  
 praze společnosti která tam byla zavřená řekněme jak jste byli ubytováni a celá řada na  
 vás udělalo domý vůbec toho tak ten první do jednoho dítěte to velice takový veliký  
 odstup času ale | je to asi tak ty kteří byli mladý ty čtrnáctiletí patnáctiletí  
 nevím do kolika let to bylo snad už šli do jugendheimu byly tam ty  
 takzvaný dětský domovy byly tam dětský domovy pro chlapce byly tam dětský domovy ... ovšem  
 je třeba se na to divat těch podmírkách ghetta tohle zní strašně vznešeně všechno to  
 byly hromadný ubikace kde na takový místo jako je tady bydlo třeba dvacet lidí to  
 zní strašně vznešeně ale šli prostě děvčata sly zvlášť chlapci šli také zvlášť ten chlaapecký  
 jugendheim teda ten domov mládeže byl v hannoveru nahoru ale mě už bylo moc a  
 našemu jirkovi také zase jsme tam byli přestárlí tak my už jsme do těch dětských  
 domovů nešli my jsme museli do mužských ubikací to znamená že já s naším jirkou  
 a s ostatními z té naší skupiny jsme byli ubytováni v hannoveru ... na půdách  
 hannoveru | ... a tam už byli před vám nějaký jak bylo plně obsazený to  
 bylo plně terezín byl plný v té době když jako přijel třeba ty spolužitelí čekali  
 jsme se přidali ... no tam se něký takový velký ale nenávisti nebo dvě zelenou  
 něco na to na úplně normálně heledeť tam byl takový veliký pohyb věžňů když si  
 uvědomite že tam bylo v době toho kdy byl terezín plný čtyřicet tisíc lidí městě  
 který mělo v míru tři tisíce obyvatel tak sem si doveďte představit jak tam byli  
 jaký tam byly podmínky tam byly třípatrový palandy ... a na těch místnostech na těch  
 půdách a řekla sem a řekla ty kasárna v těch domech bydlela strašná spousta lidu  
 ... a obměňovalo se to já sem to tam nezažil že jo ten odchod těch  
 transportů a když chodily transporty tak ty lidí odešel syrov tam přicházely | nějakou činnost  
 jste tam viděli nebo pracovního lágru museli jsme pracovat v terezíně aspoň ty co byli  
 starší museli pracovat ne- nevím jak to měli organizoval malinko zrádná konkrétně já konkrétně jak  
 sem říkal že sem pracoval u těch sedláčků tyčí čili utíkal tam tak sem trošku  
 jako přidělával u zedníků a tak sem se tam hlásil jako zedník orchestr bylo  
 takový pomocník zednický házel si tam nebyly auto odvezte nic nevěděl tak sem tam dělal  
 zedničinu a potom když tam byl postavený stan na náměstí nevím jestli tu historii znáte  
 tam byl postavený my jsme tomu říkali cirkus obrovské stan ... a němci tam zavedli  
 výrobu tak jsme byli naverbován do tohohe stanu tam se pro frontu na východě kompletovaly  
 takový soupravy do beden pro | motorový vozidla do těch velikých mrazů to znamená byla  
 tam letlampa a byly tam takový věci který každý to motorový vozidlo mělo dostat tam

Keyword



Transcript

Contains



Theresienstadt (Czechoslovakia : Ghetto)

Czechoslovakia 1943

housing conditions in the ghettos

jako tato skupina která byla po tu dobu těch třech neděl v tom v těch  
veletržních boudách tak i v terezíně jsme se potom scházeli pokud to bylo možný protože  
podporu to nařízení že se nesmí říct že se mohou stýkat muži se ženami my  
jsme tam měli také děvčata v našem věku takže jsme se potom ještě v tom  
terezíně scházeli teda v tom terezíně jednak jak se ta ... do té no v  
praze společnosti která tam byla zavřená fekněme jak jste byli ubytováni a celá řada na  
vás udělalo domý vůbec toho tak ten první do jednoho dítěte to velice takový veliký  
odstup času ale | je to asi tak ty kteří byli mladý ty čtrnáctiletí patnáctiletí  
nevím do kolika let to bylo snad už šli do jugendheimu byly tam ty  
takzvaný dětský domovy byly tam dětský domovy pro chlapce byly tam dětský domovy ... ovšem  
je třeba se na to divat těch podmírkách ghetta tohle zní strašně vznešeně všechno to  
byly hromadný ubikace kde na takový místo jako je tady bydlelo třeba dvacet lidí to  
zní strašně vznešeně ale šli prostě děvčata sly zvlášť chlapci šli také zvlášť ten chlapec  
jugendheimu teda ten domov mládeže byl v hannoveru nahoru ale mě už bylo moc a  
našemu jirkovi také zase jsme tam byli přestárlí tak my už jsme do těch dětských  
domovů nešli my jsme museli do mužských ubikací to znamená že já s naším jirkou  
a s ostatními z té naší skupiny jsme byli ubytováni v hannoveru ... na půdách  
hannoveru | ... a tam už byli před vánem nějaký jak bylo plně obsazený to  
bylo plně terezín byl plný v té době když jako přijel třeba ty spolužáci čekali  
jsme se přidali ... no tam se něký takový velký ale nenávisti nebo dvě zelenou  
něco na to na úplně normálně heledeť tam byl takový veliký pohyb věžňů když si  
uvědomite že tam bylo v době toho kdy byl terezín plný čtyřicet tisíc lidí městě  
který mělo v míru tři tisíce obyvatel tak sem si dovezdete představit jak tam byli  
jaký tam byly podmínky tam byly třípatrový palandy ... a na těch místnostech na těch  
půdách a řekla sem a ted' ty kasárna v těch domech bydlel strašná spousta lidu  
... a obměňovalo se to já sem to tam nezažil že jo ten odchod těch  
transportů a když chodily transporty tak ty lidí odešel syrov tam přicházely | nějakou činnost  
jste tam viděli nebo pracovního lágru museli jsme pracovat v terezíně aspoň ty co byli  
starší museli pracovat ne- nevím jak to měli organizoval malinko zrádná konkrétně já konkrétně jak  
sem říkal že sem pracoval u těch sedláčků tyčí čili utíkal tam tak sem trošku  
jako přidělával u zednicků a tak tak sem se tam hlásil jako zednický orchestr bylo  
takový pomocník zednický házel si tam nebylo auto odvezte nic nevěděl tak sem tam dělal  
zedničinu a potom když tam byl postavený stan na náměstí nevím jestli tu historii znáte  
tam byl postavený my jsme tomu říkali cirkus obrovské stan ... a němci tam zavedli  
výrobu tak jsme byli naverbováni do toho stanu tam se pro frontu na východě kompletovaly  
takový soupravy do beden pro | motorový vozidlo do těch velikých mrazů to znamená byla  
tam letlampa a byly tam takový věci který každý to motorový vozidlo mělo dostat tam



00:00:09


Set:




Channel 1

# Effectiveness measures


# Effectiveness measures



# Effectiveness measures




# Effectiveness measures




## Effectiveness measures

document	retrieved	not retrieved
relevant	<b>relevant retrieved</b>	<b>relevant missed</b>
not relevant	<b>false alarm</b>	<b>irrelevant rejected</b>



# Effectiveness measures

document	retrieved	not retrieved
relevant	<b>relevant retrieved</b>	<b>relevant missed</b>
not relevant	<b>false alarm</b>	<b>irrelevant rejected</b>



$$\text{Precision} = \frac{|\text{relevant retrieved}|}{|\text{retrieved}|}$$

$$\text{Recall} = \frac{|\text{relevant retrieved}|}{|\text{relevant}|}$$

## Evaluation metrics: example

$$\text{Precision} = \frac{|\text{relevant retrieved}|}{|\text{retrieved}|}$$

$$\text{Recall} = \frac{|\text{relevant retrieved}|}{|\text{relevant}|}$$

system results	
<i>int.3431-seg.125</i>	0.96
<i>int.7264-seg.068</i>	0.93
<i>int.3012-seg.142</i>	0.88
<i>int.9595-seg.119</i>	0.85
<i>int.2306-seg.120</i>	0.79
<i>int.9262-seg.131</i>	0.75
<i>int.4188-seg.033</i>	0.73
<i>int.6805-seg.007</i>	0.65
<i>int.2591-seg.123</i>	0.62
<i>int.5325-seg.015</i>	0.61
<i>int.6042-seg.038</i>	0.55
<i>int.1066-seg.149</i>	0.54
<i>int.3215-seg.071</i>	0.52
<i>int.4404-seg.023</i>	0.45
<i>int.2012-seg.121</i>	0.34
<i>int.6707-seg.116</i>	0.21

## Evaluation metrics: example

$$\text{Precision} = \frac{|\text{relevant retrieved}|}{|\text{retrieved}|}$$

$$\text{Recall} = \frac{|\text{relevant retrieved}|}{|\text{relevant}|}$$

system results	
<i>int.3431-seg.125</i>	0.96
<i>int.7264-seg.068</i>	0.93
<i>int.3012-seg.142</i>	0.88
<i>int.9595-seg.119</i>	0.85
<i>int.2306-seg.120</i>	0.79
<i>int.9262-seg.131</i>	0.75
<i>int.4188-seg.033</i>	0.73
<i>int.6805-seg.007</i>	0.65
<i>int.2591-seg.123</i>	0.62
<i>int.5325-seg.015</i>	0.61
<i>int.6042-seg.038</i>	0.55
<i>int.1066-seg.149</i>	0.54
<i>int.3215-seg.071</i>	0.52
<i>int.4404-seg.023</i>	0.45
<i>int.2012-seg.121</i>	0.34
<i>int.6707-seg.116</i>	0.21

*threshold*



## Evaluation metrics: example

$$\text{Precision} = \frac{|\text{relevant retrieved}|}{|\text{retrieved}|}$$

$$\text{Recall} = \frac{|\text{relevant retrieved}|}{|\text{relevant}|}$$

system results		classification confusion	
int.3431-seg.125	0.96	int.3431-seg.125	1
int.7264-seg.068	0.93	int.7264-seg.068	1
int.3012-seg.142	0.88	int.3012-seg.142	1
int.9595-seg.119	0.85	int.9595-seg.119	1
int.2306-seg.120	0.79	int.2306-seg.120	0
int.9262-seg.131	0.75	int.9262-seg.131	0
int.4188-seg.033	0.73	int.4188-seg.033	0
int.6805-seg.007	0.65	int.6805-seg.007	0
int.2591-seg.123	0.62	int.2591-seg.123	0
int.5325-seg.015	0.61	int.5325-seg.015	0
int.6042-seg.038	0.55	int.6042-seg.038	0
int.1066-seg.149	0.54	int.1066-seg.149	0
int.3215-seg.071	0.52	int.3215-seg.071	0
int.4404-seg.023	0.45	int.4404-seg.023	0
int.2012-seg.121	0.34	int.2012-seg.121	0
int.6707-seg.116	0.21	int.6707-seg.116	0

threshold ↘

## Evaluation metrics: example

$$\text{Precision} = \frac{|\text{relevant retrieved}|}{|\text{retrieved}|}$$

$$\text{Recall} = \frac{|\text{relevant retrieved}|}{|\text{relevant}|}$$

system results		classification confusion	
<i>int.3431-seg.125</i>	0.96	<i>int.3431-seg.125</i>	1
<i>int.7264-seg.068</i>	0.93	<i>int.7264-seg.068</i>	1
<i>int.3012-seg.142</i>	0.88	<i>int.3012-seg.142</i>	1
<i>int.9595-seg.119</i>	0.85	<i>int.9595-seg.119</i>	1
<i>int.2306-seg.120</i>	0.79	<i>int.2306-seg.120</i>	0
<i>int.9262-seg.131</i>	0.75	<i>int.9262-seg.131</i>	0
<i>int.4188-seg.033</i>	0.73	<i>int.4188-seg.033</i>	0
<i>int.6805-seg.007</i>	0.65	<i>int.6805-seg.007</i>	0
<i>int.2591-seg.123</i>	0.62	<i>int.2591-seg.123</i>	0
<i>int.5325-seg.015</i>	0.61	<i>int.5325-seg.015</i>	0
<i>int.6042-seg.038</i>	0.55	<i>int.6042-seg.038</i>	0
<i>int.1066-seg.149</i>	0.54	<i>int.1066-seg.149</i>	0
<i>int.3215-seg.071</i>	0.52	<i>int.3215-seg.071</i>	0
<i>int.4404-seg.023</i>	0.45	<i>int.4404-seg.023</i>	0
<i>int.2012-seg.121</i>	0.34	<i>int.2012-seg.121</i>	0
<i>int.6707-seg.116</i>	0.21	<i>int.6707-seg.116</i>	0

threshold



## Evaluation metrics: example

$$\text{Precision} = \frac{|\text{relevant retrieved}|}{|\text{retrieved}|}$$

$$\text{Recall} = \frac{|\text{relevant retrieved}|}{|\text{relevant}|}$$

system results		classification confusion		precision	recall
int.3431-seg.125	0.96	int.3431-seg.125	1		
int.7264-seg.068	0.93	int.7264-seg.068	1		
int.3012-seg.142	0.88	int.3012-seg.142	1		
int.9595-seg.119	0.85	int.9595-seg.119	1		
int.2306-seg.120	0.79	int.2306-seg.120	0	100 %	50 %
int.9262-seg.131	0.75	int.9262-seg.131	0		
int.4188-seg.033	0.73	int.4188-seg.033	0		
int.6805-seg.007	0.65	int.6805-seg.007	0		
int.2591-seg.123	0.62	int.2591-seg.123	0		
int.5325-seg.015	0.61	int.5325-seg.015	0		
int.6042-seg.038	0.55	int.6042-seg.038	0		
int.1066-seg.149	0.54	int.1066-seg.149	0		
int.3215-seg.071	0.52	int.3215-seg.071	0		
int.4404-seg.023	0.45	int.4404-seg.023	0		
int.2012-seg.121	0.34	int.2012-seg.121	0		
int.6707-seg.116	0.21	int.6707-seg.116	0		

## Evaluation metrics: example

$$\text{Precision} = \frac{|\text{relevant retrieved}|}{|\text{retrieved}|}$$

$$\text{Recall} = \frac{|\text{relevant retrieved}|}{|\text{relevant}|}$$

system results	
int.3431-seg.125	0.96
int.7264-seg.068	0.93
int.3012-seg.142	0.88
int.9595-seg.119	0.85
int.2306-seg.120	0.79
int.9262-seg.131	0.75
int.4188-seg.033	0.73
int.6805-seg.007	0.65
int.2591-seg.123	0.62
int.5325-seg.015	0.61
int.6042-seg.038	0.55
int.1066-seg.149	0.54
int.3215-seg.071	0.52
int.4404-seg.023	0.45
int.2012-seg.121	0.34
int.6707-seg.116	0.21

classification confusion	
int.3431-seg.125	1
int.7264-seg.068	1
int.3012-seg.142	1
int.9595-seg.119	1
int.2306-seg.120	1
int.9262-seg.131	0
int.4188-seg.033	0
int.6805-seg.007	0
int.2591-seg.123	0
int.5325-seg.015	0
int.6042-seg.038	0
int.1066-seg.149	0
int.3215-seg.071	0
int.4404-seg.023	0
int.2012-seg.121	0
int.6707-seg.116	0

precision	recall
100 %	50 %

## Evaluation metrics: example

$$\text{Precision} = \frac{|\text{relevant retrieved}|}{|\text{retrieved}|}$$

$$\text{Recall} = \frac{|\text{relevant retrieved}|}{|\text{relevant}|}$$

system results	
int.3431-seg.125	0.96
int.7264-seg.068	0.93
int.3012-seg.142	0.88
int.9595-seg.119	0.85
int.2306-seg.120	0.79
int.9262-seg.131	0.75
int.4188-seg.033	0.73
int.6805-seg.007	0.65
int.2591-seg.123	0.62
int.5325-seg.015	0.61
int.6042-seg.038	0.55
int.1066-seg.149	0.54
int.3215-seg.071	0.52
int.4404-seg.023	0.45
int.2012-seg.121	0.34
int.6707-seg.116	0.21

classification confusion	
int.3431-seg.125	1
int.7264-seg.068	1
int.3012-seg.142	1
int.9595-seg.119	1
int.2306-seg.120	1
int.9262-seg.131	0
int.4188-seg.033	0
int.6805-seg.007	0
int.2591-seg.123	0
int.5325-seg.015	0
int.6042-seg.038	0
int.1066-seg.149	0
int.3215-seg.071	0
int.4404-seg.023	0
int.2012-seg.121	0
int.6707-seg.116	0

precision	recall
100 %	50 %
80 %	50 %

## Evaluation metrics: example

$$\text{Precision} = \frac{|\text{relevant retrieved}|}{|\text{retrieved}|}$$

$$\text{Recall} = \frac{|\text{relevant retrieved}|}{|\text{relevant}|}$$

system results	
int.3431-seg.125	0.96
int.7264-seg.068	0.93
int.3012-seg.142	0.88
int.9595-seg.119	0.85
int.2306-seg.120	0.79
int.9262-seg.131	0.75
int.4188-seg.033	0.73
int.6805-seg.007	0.65
int.2591-seg.123	0.62
int.5325-seg.015	0.61
int.6042-seg.038	0.55
int.1066-seg.149	0.54
int.3215-seg.071	0.52
int.4404-seg.023	0.45
int.2012-seg.121	0.34
int.6707-seg.116	0.21

classification confusion	
int.3431-seg.125	1
int.7264-seg.068	1
int.3012-seg.142	1
int.9595-seg.119	1
int.2306-seg.120	1
int.9262-seg.131	1
int.4188-seg.033	0
int.6805-seg.007	0
int.2591-seg.123	0
int.5325-seg.015	0
int.6042-seg.038	0
int.1066-seg.149	0
int.3215-seg.071	0
int.4404-seg.023	0
int.2012-seg.121	0
int.6707-seg.116	0

precision	recall
100 %	50 %
80 %	50 %

## Evaluation metrics: example

$$\text{Precision} = \frac{|\text{relevant retrieved}|}{|\text{retrieved}|}$$

$$\text{Recall} = \frac{|\text{relevant retrieved}|}{|\text{relevant}|}$$

system results	
int.3431-seg.125	0.96
int.7264-seg.068	0.93
int.3012-seg.142	0.88
int.9595-seg.119	0.85
int.2306-seg.120	0.79
int.9262-seg.131	0.75
int.4188-seg.033	0.73
int.6805-seg.007	0.65
int.2591-seg.123	0.62
int.5325-seg.015	0.61
int.6042-seg.038	0.55
int.1066-seg.149	0.54
int.3215-seg.071	0.52
int.4404-seg.023	0.45
int.2012-seg.121	0.34
int.6707-seg.116	0.21

classification confusion	
int.3431-seg.125	1
int.7264-seg.068	1
int.3012-seg.142	1
int.9595-seg.119	1
int.2306-seg.120	1
int.9262-seg.131	1
int.4188-seg.033	0
int.6805-seg.007	0
int.2591-seg.123	0
int.5325-seg.015	0
int.6042-seg.038	0
int.1066-seg.149	0
int.3215-seg.071	0
int.4404-seg.023	0
int.2012-seg.121	0
int.6707-seg.116	0

precision	recall
100 %	50 %
80 %	50 %
83 %	62 %

## Evaluation metrics: example

$$\text{Precision} = \frac{|\text{relevant retrieved}|}{|\text{retrieved}|}$$

$$\text{Recall} = \frac{|\text{relevant retrieved}|}{|\text{relevant}|}$$

system results	
int.3431-seg.125	0.96
int.7264-seg.068	0.93
int.3012-seg.142	0.88
int.9595-seg.119	0.85
int.2306-seg.120	0.79
int.9262-seg.131	0.75
int.4188-seg.033	0.73
int.6805-seg.007	0.65
int.2591-seg.123	0.62
int.5325-seg.015	0.61
int.6042-seg.038	0.55
int.1066-seg.149	0.54
int.3215-seg.071	0.52
int.4404-seg.023	0.45
int.2012-seg.121	0.34
int.6707-seg.116	0.21

classification confusion	
int.3431-seg.125	1
int.7264-seg.068	1
int.3012-seg.142	1
int.9595-seg.119	1
int.2306-seg.120	1
int.9262-seg.131	1
int.4188-seg.033	1
int.6805-seg.007	0
int.2591-seg.123	0
int.5325-seg.015	0
int.6042-seg.038	0
int.1066-seg.149	0
int.3215-seg.071	0
int.4404-seg.023	0
int.2012-seg.121	0
int.6707-seg.116	0

precision	recall
100 %	50 %
80 %	50 %
83 %	62 %

## Evaluation metrics: example

$$\text{Precision} = \frac{|\text{relevant retrieved}|}{|\text{retrieved}|}$$

$$\text{Recall} = \frac{|\text{relevant retrieved}|}{|\text{relevant}|}$$

system results	
int.3431-seg.125	0.96
int.7264-seg.068	0.93
int.3012-seg.142	0.88
int.9595-seg.119	0.85
int.2306-seg.120	0.79
int.9262-seg.131	0.75
int.4188-seg.033	0.73
int.6805-seg.007	0.65
int.2591-seg.123	0.62
int.5325-seg.015	0.61
int.6042-seg.038	0.55
int.1066-seg.149	0.54
int.3215-seg.071	0.52
int.4404-seg.023	0.45
int.2012-seg.121	0.34
int.6707-seg.116	0.21

classification confusion	
int.3431-seg.125	1
int.7264-seg.068	1
int.3012-seg.142	1
int.9595-seg.119	1
int.2306-seg.120	1
int.9262-seg.131	1
int.4188-seg.033	1
int.6805-seg.007	0
int.2591-seg.123	0
int.5325-seg.015	0
int.6042-seg.038	0
int.1066-seg.149	0
int.3215-seg.071	0
int.4404-seg.023	0
int.2012-seg.121	0
int.6707-seg.116	0

precision	recall
100 %	50 %
80 %	50 %
83 %	62 %
85 %	75 %

## Evaluation metrics: example

$$\text{Precision} = \frac{|\text{relevant retrieved}|}{|\text{retrieved}|}$$

$$\text{Recall} = \frac{|\text{relevant retrieved}|}{|\text{relevant}|}$$

system results	
int.3431-seg.125	0.96
int.7264-seg.068	0.93
int.3012-seg.142	0.88
int.9595-seg.119	0.85
int.2306-seg.120	0.79
int.9262-seg.131	0.75
int.4188-seg.033	0.73
int.6805-seg.007	0.65
int.2591-seg.123	0.62
int.5325-seg.015	0.61
int.6042-seg.038	0.55
int.1066-seg.149	0.54
int.3215-seg.071	0.52
int.4404-seg.023	0.45
int.2012-seg.121	0.34
int.6707-seg.116	0.21

classification confusion	
int.3431-seg.125	1
int.7264-seg.068	1
int.3012-seg.142	1
int.9595-seg.119	1
int.2306-seg.120	1
int.9262-seg.131	1
int.4188-seg.033	1
int.6805-seg.007	1
int.2591-seg.123	0
int.5325-seg.015	0
int.6042-seg.038	0
int.1066-seg.149	0
int.3215-seg.071	0
int.4404-seg.023	0
int.2012-seg.121	0
int.6707-seg.116	0

precision	recall
100 %	50 %
80 %	50 %
83 %	62 %
85 %	75 %
75 %	75 %

## Evaluation metrics: example

$$\text{Precision} = \frac{|\text{relevant retrieved}|}{|\text{retrieved}|}$$

$$\text{Recall} = \frac{|\text{relevant retrieved}|}{|\text{relevant}|}$$

system results		classification confusion		precision	recall
<i>int.3431-seg.125</i>	0.96	<i>int.3431-seg.125</i>	1		
<i>int.7264-seg.068</i>	0.93	<i>int.7264-seg.068</i>	1		
<i>int.3012-seg.142</i>	0.88	<i>int.3012-seg.142</i>	1		
<i>int.9595-seg.119</i>	0.85	<i>int.9595-seg.119</i>	1	100 %	50 %
<i>int.2306-seg.120</i>	0.79	<i>int.2306-seg.120</i>	1	80 %	50 %
<i>int.9262-seg.131</i>	0.75	<i>int.9262-seg.131</i>	1	83 %	62 %
<i>int.4188-seg.033</i>	0.73	<i>int.4188-seg.033</i>	1	85 %	75 %
<i>int.6805-seg.007</i>	0.65	<i>int.6805-seg.007</i>	1	75 %	75 %
<i>int.2591-seg.123</i>	0.62	<i>int.2591-seg.123</i>	1	77 %	87 %
<i>int.5325-seg.015</i>	0.61	<i>int.5325-seg.015</i>	0		
<i>int.6042-seg.038</i>	0.55	<i>int.6042-seg.038</i>	0		
<i>int.1066-seg.149</i>	0.54	<i>int.1066-seg.149</i>	0		
<i>int.3215-seg.071</i>	0.52	<i>int.3215-seg.071</i>	0		
<i>int.4404-seg.023</i>	0.45	<i>int.4404-seg.023</i>	0		
<i>int.2012-seg.121</i>	0.34	<i>int.2012-seg.121</i>	0		
<i>int.6707-seg.116</i>	0.21	<i>int.6707-seg.116</i>	0		

## Evaluation metrics: example

$$\text{Precision} = \frac{|\text{relevant retrieved}|}{|\text{retrieved}|}$$

$$\text{Recall} = \frac{|\text{relevant retrieved}|}{|\text{relevant}|}$$

system results	
<i>int.3431-seg.125</i>	0.96
<i>int.7264-seg.068</i>	0.93
<i>int.3012-seg.142</i>	0.88
<i>int.9595-seg.119</i>	0.85
<i>int.2306-seg.120</i>	0.79
<i>int.9262-seg.131</i>	0.75
<i>int.4188-seg.033</i>	0.73
<i>int.6805-seg.007</i>	0.65
<i>int.2591-seg.123</i>	0.62
<i>int.5325-seg.015</i>	0.61
<i>int.6042-seg.038</i>	0.55
<i>int.1066-seg.149</i>	0.54
<i>int.3215-seg.071</i>	0.52
<i>int.4404-seg.023</i>	0.45
<i>int.2012-seg.121</i>	0.34
<i>int.6707-seg.116</i>	0.21

classification confusion	
<i>int.3431-seg.125</i>	1
<i>int.7264-seg.068</i>	1
<i>int.3012-seg.142</i>	1
<i>int.9595-seg.119</i>	1
<i>int.2306-seg.120</i>	1
<i>int.9262-seg.131</i>	1
<i>int.4188-seg.033</i>	1
<i>int.6805-seg.007</i>	1
<i>int.2591-seg.123</i>	1
<i>int.5325-seg.015</i>	1
<i>int.6042-seg.038</i>	0
<i>int.1066-seg.149</i>	0
<i>int.3215-seg.071</i>	0
<i>int.4404-seg.023</i>	0
<i>int.2012-seg.121</i>	0
<i>int.6707-seg.116</i>	0

precision	recall
100 %	50 %
80 %	50 %
83 %	62 %
85 %	75 %
75 %	75 %
77 %	87 %
70 %	87 %

## Evaluation metrics: example

$$\text{Precision} = \frac{|\text{relevant retrieved}|}{|\text{retrieved}|}$$

$$\text{Recall} = \frac{|\text{relevant retrieved}|}{|\text{relevant}|}$$

system results		classification confusion		precision	recall
<i>int.3431-seg.125</i>	0.96	<i>int.3431-seg.125</i>	1		
<i>int.7264-seg.068</i>	0.93	<i>int.7264-seg.068</i>	1		
<i>int.3012-seg.142</i>	0.88	<i>int.3012-seg.142</i>	1		
<i>int.9595-seg.119</i>	0.85	<i>int.9595-seg.119</i>	1	100 %	50 %
<i>int.2306-seg.120</i>	0.79	<i>int.2306-seg.120</i>	1	80 %	50 %
<i>int.9262-seg.131</i>	0.75	<i>int.9262-seg.131</i>	1	83 %	62 %
<i>int.4188-seg.033</i>	0.73	<i>int.4188-seg.033</i>	1	85 %	75 %
<i>int.6805-seg.007</i>	0.65	<i>int.6805-seg.007</i>	1	75 %	75 %
<i>int.2591-seg.123</i>	0.62	<i>int.2591-seg.123</i>	1	77 %	87 %
<i>int.5325-seg.015</i>	0.61	<i>int.5325-seg.015</i>	1	70 %	87 %
<i>int.6042-seg.038</i>	0.55	<i>int.6042-seg.038</i>	1	72 %	100 %
<i>int.1066-seg.149</i>	0.54	<i>int.1066-seg.149</i>	0		
<i>int.3215-seg.071</i>	0.52	<i>int.3215-seg.071</i>	0		
<i>int.4404-seg.023</i>	0.45	<i>int.4404-seg.023</i>	0		
<i>int.2012-seg.121</i>	0.34	<i>int.2012-seg.121</i>	0		
<i>int.6707-seg.116</i>	0.21	<i>int.6707-seg.116</i>	0		

## Evaluation metrics: example

$$\text{Precision} = \frac{|\text{relevant retrieved}|}{|\text{retrieved}|}$$


$$\text{Recall} = \frac{|\text{relevant retrieved}|}{|\text{relevant}|}$$

system results	
int.3431-seg.125	0.91
int.7264-seg.068	0.93
int.3012-seg.142	0.88
int.9595-seg.119	0.85
int.2306-seg.120	0.79
int.9262-seg.131	0.75
int.4188-seg.033	0.73
int.6805-seg.007	0.65
int.2591-seg.123	0.62
int.5325-seg.015	0.61
int.6042-seg.038	0.55
int.1066-seg.149	0.54
int.3215-seg.071	0.52
int.4404-seg.023	0.45
int.2012-seg.121	0.34
int.6707-seg.116	0.21

classification confusion	
int.3431-seg.125	1
int.7264-seg.068	1
int.3012-seg.142	1
int.9595-seg.119	1
int.2306-seg.120	1
int.9262-seg.131	1
int.4188-seg.033	1
int.6805-seg.007	1
int.2591-seg.123	1
int.5325-seg.015	1
int.6042-seg.038	1
int.1066-seg.149	1
int.3215-seg.071	1
int.4404-seg.023	1
int.2012-seg.121	1
int.6707-seg.116	1


precision	recall
100 %	12 %
100 %	25 %
100 %	37 %
100 %	50 %
80 %	50 %
83 %	62 %
85 %	75 %
75 %	75 %
77 %	87 %
70 %	87 %
72 %	100 %
66 %	100 %
61 %	100 %
57 %	100 %
53 %	100 %
50 %	100 %

## Precision–recall curves




## Average precision

- ▶ the expected value of precision for all possible values of recall
- ▶ equal to the area under the precision–recall curve (AUC)




## Average precision


- ▶ the expected value of precision for all possible values of recall
- ▶ equal to the area under the precision–recall curve (AUC)




# Mean average precision



# Mean average precision



## Mean average precision



### Measuring improvement

- ▶ Meaningful improvement: *0.05 is noticeable, 0.1 makes a difference*
- ▶ Reliable improvement: *Wilcoxon signed rank test for paired samples*
- ▶ Maximum precision limit: *set by inter-assessors agreement*

# Cross-Language Evaluation Forum (CLEF)

- ▶ an activity of the *DELOS Network of Excellence for Digital Libraries* under the *Sixth Framework Programme of the European Commission*
- ▶ develops an infrastructure for testing, tuning, and evaluation of IR systems on European languages in both monolingual and cross-language contexts
- ▶ creates test-suites of reusable data which can be employed by system developers for benchmarking purposes.
- ▶ offers a series of evaluation tracks to test different aspects of cross-language information retrieval system development:

1. Mono-, Bi- and Multilingual Document Retrieval on News Collections
2. Mono and Cross-Language IR on Structured Scientific Data
3. Interactive Cross-Language IR
4. Multiple Language Question Answering
5. Cross-Language Retrieval in Image Collections
6. Multilingual Web Track (WebCLEF)
7. Cross-Language Speech Retrieval
8. Cross-Language Geographical Retrieval

# CLEF 2006 Cross-language speech retrieval track overview

Two tasks: English segments, Czech start times

- ▶ Max of 5 official runs per team per task
- ▶ Baseline English run: ASR / English TD topics

7 teams / 6 countries

- ▶ Canada: *Ottawa* (EN, CZ)
- ▶ Czech Rep: *West Bohemia* (CZ)
- ▶ Ireland: DCU (EN)
- ▶ Netherlands: *Twente* (EN)
- ▶ Spain: *Alicante* (EN), *UNED* (EN)
- ▶ USA: *Maryland* (EN, CZ)

---

## Schedule

Jan 15 Registration opened

Apr 14 Data release

May 1 Topic release

Jun 6 Submission of runs by participants

Aug 1 Release of relevance assessments and individual results


Aug 8 Submission of paper for Working Notes

Sep 20 Workshop (Alicante, Spain)

# English results (MAP)

Queries: title + description


Documents: ASR output



# English results (MAP)

Queries: title + description

Documents: ASR output



# Monolingual vs. cross-language comparisons (MAP)

Queries: title/description/narrative

Documents: ASR output, metadata, both

Team	Q	D	English	French	Dutch	Spanish
Ottawa	TDN	Meta	0.2902			
Twente	T	Meta	0.2058		80%	
DCU	TD	Both	0.2015	79%		
Maryland	TD	Meta	0.2350	44%		
UNED	TD	Meta	0.1766			51%
Ottawa	TDN	ASR	0.0768	83%		81%
DCU	TD	ASR	0.0733	63%		
Twente	T	ASR	0.0495		77%	
UNED	TD	ASR	0.0376			68%
Maryland	TD	ASR	0.0543	38%		

# Conclusion

## Call for participation: CLEF 2007

- ▶ Registration Opens - *15 January 2007*
- ▶ Data Release - *15 February 2007*
- ▶ Topic Release - *1 April 2007*
- ▶ Submission of Runs by Participants - *15 June 2007*
- ▶ Release of Relevance Assessments and Individual Results - *15 July 2007*
- ▶ Submission of Paper for Working Notes - *15 August 2007*
- ▶ Workshop - *19–21 September 2007*

1. Multilingual Document Retrieval on News Collections
2. Scientific Data Retrieval
3. Interactive Cross-Language Information Retrieval
4. Multiple Language Question Answering
5. Cross-Language Image Retrieval
6. Cross-Language Spoken Retrieval
7. CLEF Web Track
8. Cross-Language Geographical Information Retrieval

Thank You!

## People said ...

### Doug Greenberg:

- ▶ “We don’t edit any of these interviews. It’s completely raw footage taken directly from interviews with survivors. It will be broadly accessible, but it won’t be edited.”
- ▶ “Our mission now is to use the archive in educational settings to overcome prejudice and bigotry.”

### Doug Oard:

- ▶ “There’s a lot more oral history than anybody even knows about”.
- ▶ “It isn’t as good as a human cataloging, but it’s \$100 million cheaper.”
- ▶ “When you develop this type of technology, you open a lot of doors,”

# Links

- ▶ Shoah Foundation / Visual History Institute  
<http://www.usc.edu/schools/college/vhi/>
- ▶ Malach Project  
<http://malach.umiacs.umd.edu/>
- ▶ Cross-Language Evaluation Forum  
<http://www.clef-campaign.org/>
- ▶ Cross-Language Speech Retrieval track of CLEF  
<http://clef-clsr.umiacs.umd.edu/>