Semantic Components: A model for enhancing retrieval of domain-specific information

Lecture 22
CS 410/510
Information Retrieval on the Internet

Pathway Project Team

- Susan Price, MD Portland State University
- Lois Delcambre, PhD, Portland State University
- Marianne Lykke Nielsen, PhD, Royal School of Library & Information Science
- Tim Tolle, PhD, Hydrology USDA Forest Service, retired
- Vibeke Luk, MLS sundhed.dk
- Mat Weaver, PhD, CS EarthSoft, Inc.

Supporting domain experts using domain-specific digital libraries

- Domain experts often have specific information needs, perhaps related to a particular task
  - Example: physician seeing pt with chronic asthma, newly pregnant
  - Retrieved documents should be relevant to the task or question (not just about the topic)
  - Time for searching may be limited

Focus

- Support users who
  - Know how domain information is organized and expressed
  - Know types of documents available
- Using domain-specific digital libraries
  - Documents + retrieval system
  - Often lacks benefit of web hyperlink structure
- For precision-oriented information needs
  - Specific need
  - Satisfied by one, or a few, documents

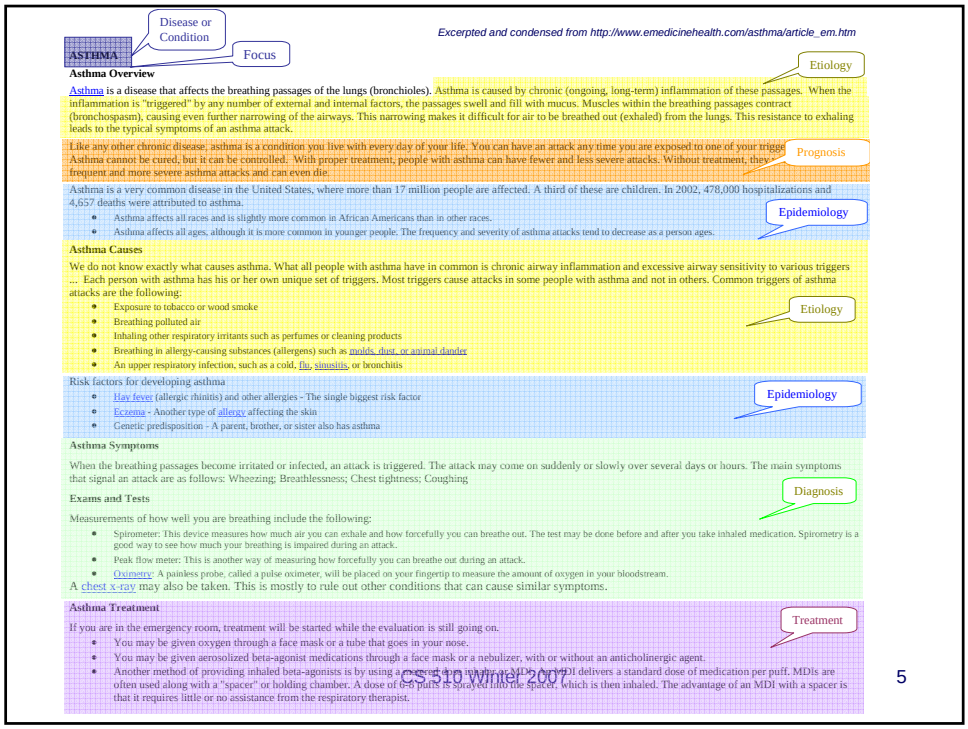

Basic idea: search on main topic; refine by searching within components

find information about treating asthma with salmeterol during pregnancy

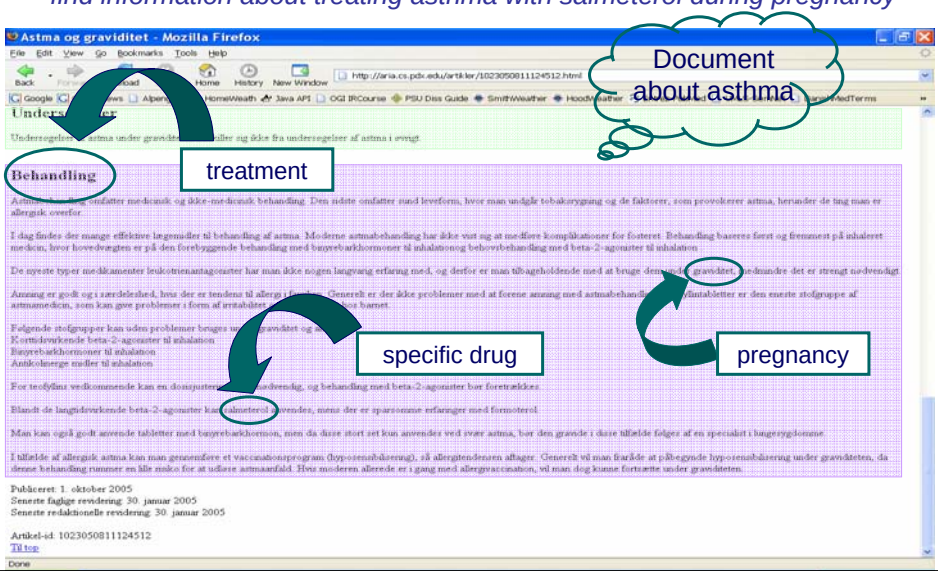

Our approach

- Leverage user's knowledge
  - of the types of documents available
  - of the kinds of information in the documents
  - by allowing user to specify search using domain-specific components of documents (not necessarily structural)

Our approach

- Supplemental indexing that allows search within segments of documents
- Orthogonal to (and can be combined with) other indexing techniques
  - Full text indexing
  - Keyword indexing
    - Subject description
    - Other metadata

Our settings

- sundhed.dk: national Danish health portal
  - Serves needs of clinicians and citizens
  - 24,000+ documents
  - In use since 2001
- USDA Forest service
  - Primarily documents mandated by the National Environmental Protection Act (NEPA)
  - Research portal

Semantic component model

- Document classes (genres)
  - Classifications of documents: type of topic, purpose
  - Documents: about a *disease*, about a *clinical method*, about a *drug*, about a *clinical unit*
- Semantic components
  - Each document class associated with a small set of semantic components
  - Document about a disease: *treatment*, *evaluation*, *referral*
  - Document about a drug: *target group*, *side effects*, *indications*
- Semantic component instances
  - Segments of text with information about a semantic component
  - Variable length, may be nested or discontiguous

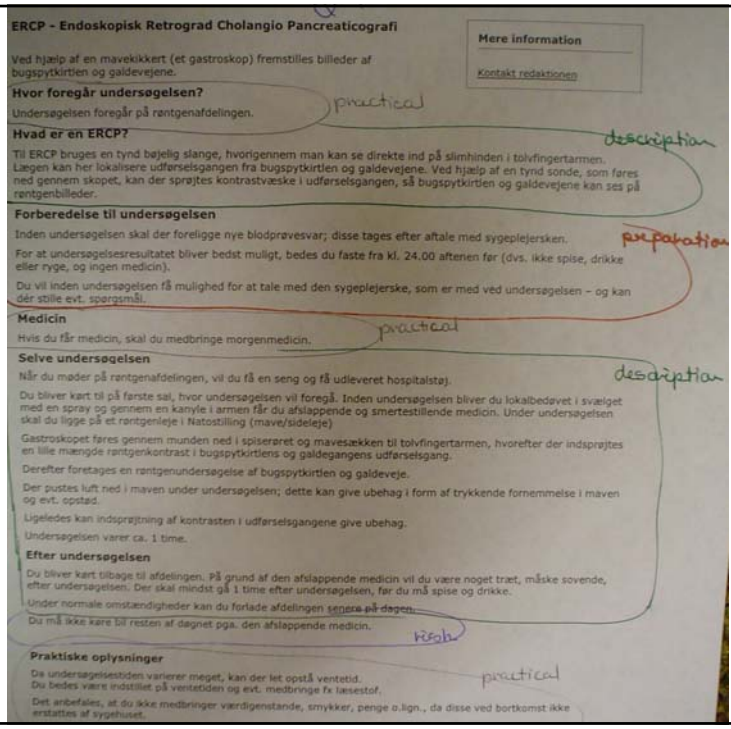

ERCP - Endoskopisk Retrograd Cholangio Pancreaticografi

Mere information

Kontakt redaktionen

Ved hjælp af en mavekikkert (et gastroskop) fremstilles billeder af bugspytkirtlen og galdevejene.

Hvor foregår undersøgelsen?

Undersøgelsen foregår på røntgenafdelingen.

Hvad er en ERCP?

Til ERCP bruges en tynd bøjelig slange, hvorigennem man kan se direkte ind på slimhinden i tolvfingertarmen. Lægen kan her lokalisere udførselsgangen fra bugspytkirtlen og galdevejene. Ved hjælp af en tynd sonde, som føres ned gennem skopet, kan der sprøjtes kontrastvæske i udførselsgangen, så bugspytkirtlen og galdevejene kan ses på røntgenbilleder.

Forberedelse til undersøgelsen

Inden undersøgelsen skal der foreligge nye blodprøvesvar; disse tages efter aftale med sygeplejersken.

For at undersøgelsesresultatet bliver bedst muligt, bedes du faste fra kl. 24.00 aftenen før (dvs. ikke spise, drikke eller ryge, og ingen medicin).

Du vil inden undersøgelsen få mulighed for at tale med den sygeplejerske, som er med ved undersøgelsen – og kan dér stille evt. spørgsmål.

Medicin

Hvis du får medicin, skal du medbringe morgenmedicin.

Selve undersøgelsen

Når du møder på røntgenafdelingen, vil du få en seng og få udleveret hospitalstøj.

Du bliver kørt til på første sal, hvor undersøgelsen vil foregå. Inden undersøgelsen bliver du lokalbedøvet i svælget med en spray og gennem en kanyle i armen får du afslappende og smertestillende medicin. Under undersøgelsen skal du ligge på et røntgenleje i Natostilling (mave/sideleje)

Gastroskopet føres gennem munden ned i spiserøret og mavesækken til tolvfingertarmen, hvorefter der indsprøjtes en lille mængde røntgenkontrast i bugspytkirtlens og galdegangens udførselsgang.

Derefter foretages en røntgenundersøgelse af bugspytkirtlen og galdeveje.

Der pustes luft ned i maven under undersøgelsen; dette kan give ubehag i form af trykkende fornemmelse i maven og evt. opstød.

Ligeledes kan indsprøjtning af kontrasten i udførselsgangene give ubehag.

Undersøgelsen varer ca. 1 time.

Efter undersøgelsen

Du bliver kørt tilbage til afdelingen. På grund af den afslappende medicin vil du være noget træt, måske sovende, efter undersøgelsen. Der skal mindst gå 1 time efter undersøgelsen, før du må spise og drikke.

Under normale omstændigheder kan du forlade afdelingen senere på dagen.

Du må ikke køre bil resten af døgnet pga. den afslappende medicin.

Praktiske oplysninger

Da undersøgelsestiden varierer meget, kan der let opstå ventetid.
Du bedes være indstillet på ventetiden og evt. medbringe fx læsestof.

Det anbefales, at du ikke medbringer værdigenstande, smykker, penge o.lign., da disse ved bortkomst ikke erstattes af sygehuset.

practical

description

preparation

practical

description

risk

practical

11

Using semantic components

- Searching for documents with particular semantic components
  - Allow user to specify aspects of interest
- Searching within semantic components
  - Focus search on terms associated with a particular aspect of a topic
- Profiling documents in search results
  - Help user decide which documents to look at

Four main areas of inquiry

1. Are semantic components useful for retrieving documents?
2. How easily can semantic components be identified and represented in an index?
3. Can searchers express information needs using document types and semantic components?
4. Can document classes and semantic components be identified for a particular domain-specific document collection?

1. Searching with semantic components

- Can physicians using a search system with semantic components successfully complete search scenarios more quickly than using a basic search system without semantic components?
- Do physicians' searches using a search system with semantic components result in better search performance than when using a basic system without semantic components?

Experimental search system

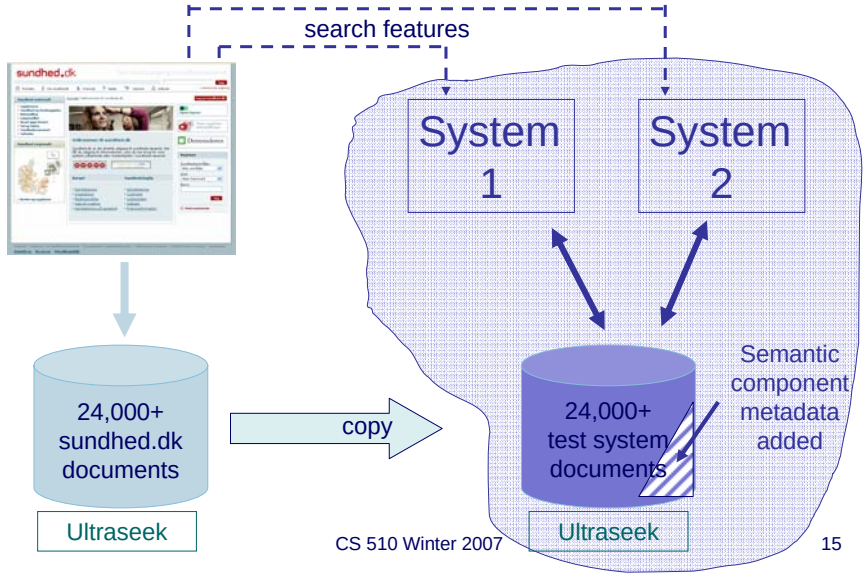

System 1 ("Basic") interface

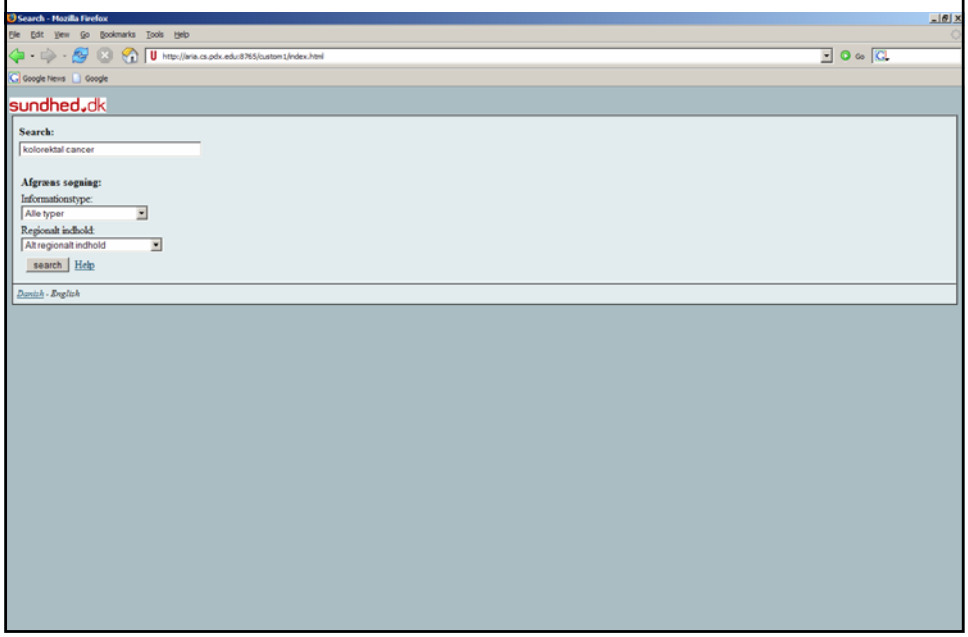

System 2 search interface

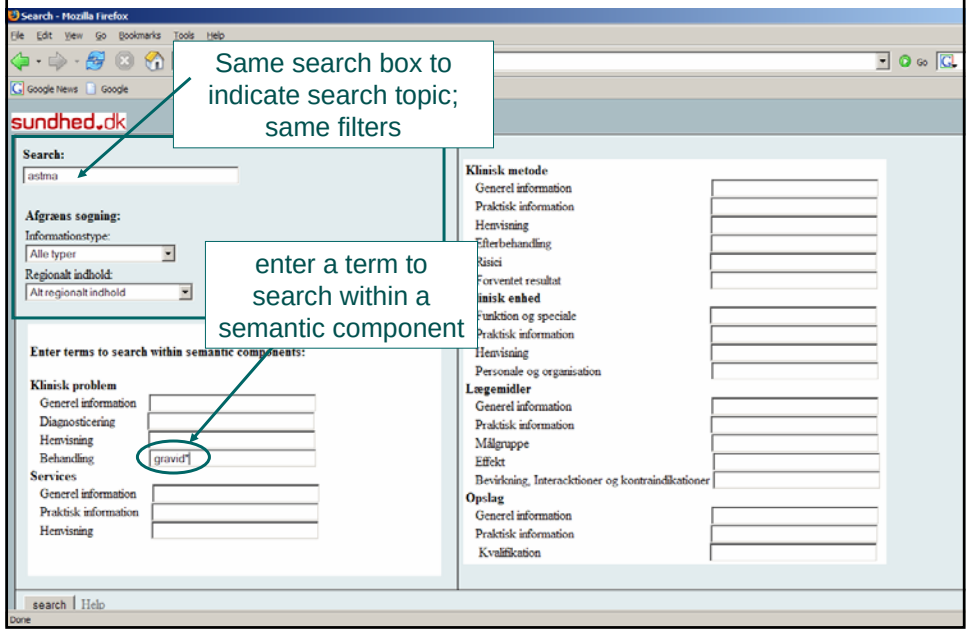

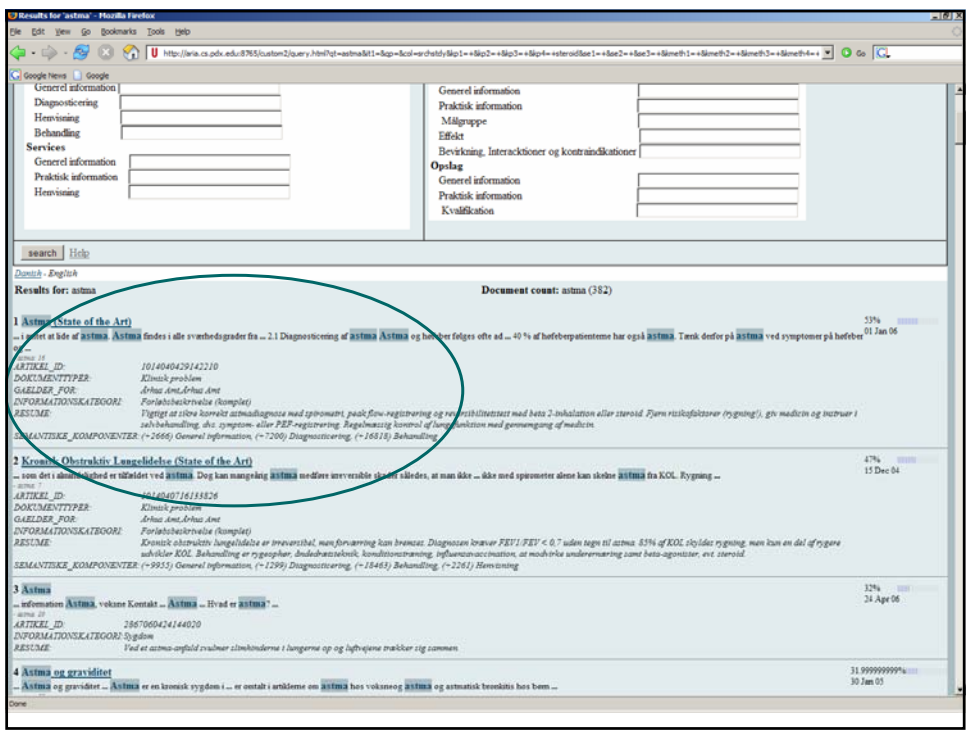

Search study experimental design

- Subjects: 30 Danish physicians who use sundhed.dk
- Intro/training to each system with guided practice
- Tasks: four search scenarios
  - Realistic, representative tasks
  - Designed in collaboration with a Danish physician/researcher
  - Two tasks with each system (randomized sequence of tasks and systems)

Search study experimental design (2)

- Data collection:
  - Search logs: queries, time, search results
  - Graded relevance assessments (explicit user relevance, implicit via click-through)
  - User satisfaction and feedback (questionnaires)

Searching study: Preliminary results

1. Do semantic components improve speed?

Clock time

System	Average duration per session				
	Scenario A	Scenario B	Scenario C	Scenario D	All scenarios
1	04:26	08:49	04:53	05:03	05:48
2	06:05	09:15	07:35	05:47	07:10

Search iterations

System	Number of search iterations per session (mean ± std. dev.)				
	Scenario A	Scenario B	Scenario C	Scenario D	All scenarios
1	1.67 ± 1.18	3.93 ± 2.15	1.87 ± 1.36	2.67 ± 1.88	2.53 ± 1.87
2	1.60 ± 0.99	4.33 ± 2.72	3.47 ± 2.59	3.33 ± 2.23	3.18 ± 2.40

Searching study: Preliminary results

2. Do sem. comp. improve search performance?

User perspective

- Number of successful search sessions
- Rank of "best" relevant document

System perspective

- Ranking of all relevant documents
  - Based on reference standard
  - "Best query" versus session discounting
  - Using MAP
  - Using graded relevance metric

Searching study: User perspective

- Number of successful search sessions

System	**Number of successful sessions**				
	Scenario A	Scenario B	Scenario C	Scenario D	All scenarios
1	14	9	15	14	52
2	15	10	15	15	55

- Rank of "best" relevant document

System	Average reciprocal rank of the best user-relevant document				
	Scenario A	Scenario B	Scenario C	Scenario D	All scenarios
1	0.75	0.30	0.45	0.53	0.51
2	0.83	0.47	0.38	0.58	0.57

Searching study: System perspective

"Best" query in each search session

- Mean average precision (highly relevant docs)

System	Mean Average Precision				
	Scenario A	Scenario B	Scenario C	Scenario D	All scenarios
1	0.28	0.53	0.21	0.19	0.31
2	0.56	0.58	0.26	0.27	0.42

- Discounted cumulative gain

System	Average Normalized Discounted Cumulative Gain				
	Scenario A	Scenario B	Scenario C	Scenario D	All scenarios
1	0.41	0.59	0.37	0.34	0.43
2	0.60	0.60	0.48	0.46	0.53

2. Indexing with semantic components

- Is semantic component indexing of sundhed.dk documents more consistent than keyword indexing of the same documents?
- Is semantic component indexing of sundhed.dk documents more accurate than keyword indexing compared to a reference standard?
- Is semantic component indexing of sundhed.dk documents faster than keyword indexing?
- Is semantic component indexing of sundhed.dk documents easier than keyword indexing, as perceived by the indexers?

Indexing study experimental design

- Subjects: 16 Danish indexers
  - who keyword index documents for sundhed.dk
- Tasks: 12 existing sundhed.dk documents
  - Index 6 documents with semantic components
  - Index 6 documents with keywords
- Data collection:
  - Indexing data (on paper to avoid UI issues)
  - Time
  - User ease, confidence, satisfaction, and feedback (questionnaires)

Semantic component indexing

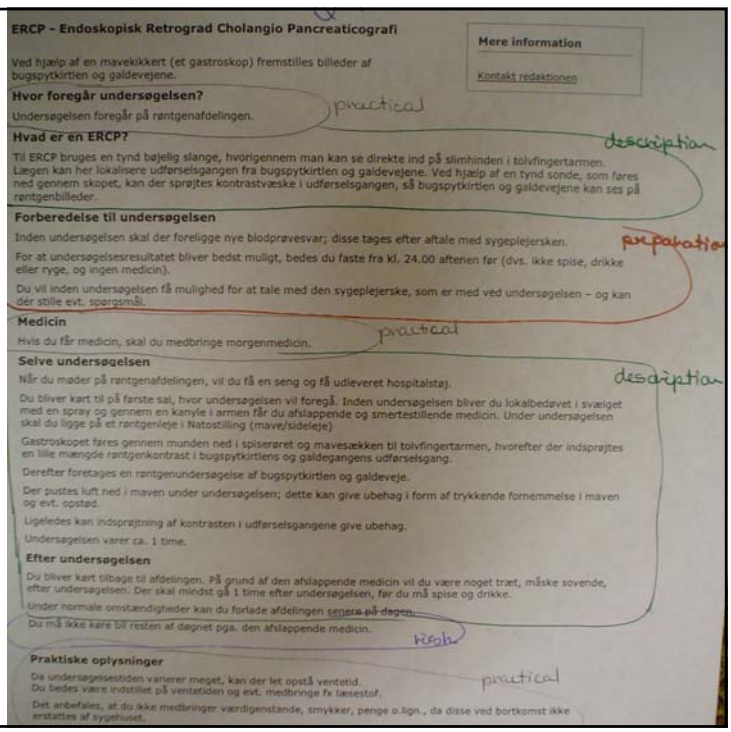

ERCP - Endoskopisk Retrograd Cholangio Pancreaticografi

Mere information

Kontakt redaktionen

Ved hjælp af en mavekikkert (et gastroskop) fremstilles billeder af bugspytkirtlen og galdevejene.

Hvor foregår undersøgelsen? practical

Undersøgelsen foregår på røntgenafdelingen.

Hvad er en ERCP? description

Til ERCP bruges en tynd bøjelig slange, hvorigennem man kan se direkte ind på slimhinden i tolvfingertarmen. Lægen kan her lokalisere udførselsgangen fra bugspytkirtlen og galdevejene. Ved hjælp af en tynd sonde, som føres ned gennem skopet, kan der sprøjtes kontrastvæske i udførselsgangen, så bugspytkirtlen og galdevejene kan ses på røntgenbilleder.

Forberedelse til undersøgelsen preparation

Inden undersøgelsen skal der foreligge nye blodprøvesvar; disse tages efter aftale med sygeplejersken.

For at undersøgelsesresultatet bliver bedst muligt, bedes du faste fra kl. 24.00 aftenen før (dvs. ikke spise, drikke eller ryge, og ingen medicin).

Du vil inden undersøgelsen få mulighed for at tale med den sygeplejerske, som er med ved undersøgelsen - og kan dér stille evt. spørgsmål.

Medicin practical

Hvis du får medicin, skal du medbringe morgenmedicin.

Selve undersøgelsen description

Når du møder på røntgenafdelingen, vil du få en seng og få udleveret hospitalstøj.

Du bliver kørt til på første sal, hvor undersøgelsen vil foregå. Inden undersøgelsen bliver du lokalbedøvet i svælget med en spray og gennem en kanyle i armen får du afslappende og smertestillende medicin. Under undersøgelsen skal du ligge på et røntgenleje i Natostilling (mave/sideleje)

Gastroskopet føres gennem munden ned i spiserøret og mavesækken til tolvfingertarmen, hvorefter der indsprøjtes en lille mængde røntgenkontrast i bugspytkirtlens og galdegangens udførselsgang.

Derefter foretages en røntgenundersøgelse af bugspytkirtlen og galdeveje.

Der pustes luft ned i maven under undersøgelsen; dette kan give ubehag i form af trykkende fornemmelse i maven og evt. opstød.

Ligeledes kan indsprøjtning af kontrasten i udførselsgangene give ubehag.

Undersøgelsen varer ca. 1 time.

Efter undersøgelsen

Du bliver kørt tilbage til afdelingen. På grund af den afslappende medicin vil du være noget træt, måske sovende, efter undersøgelsen. Der skal mindst gå 1 time efter undersøgelsen, før du må spise og drikke.

Under normale omstændigheder kan du forlade afdelingen senere på dagen.

Du må ikke køre bil resten af døgnet pga. den afslappende medicin.

Praktiske oplysninger practical

Da undersøgelsestiden varierer meget, kan der let opstå ventetid.
Du bedes være indstillet på ventetiden og evt. medbringe fx læsestof.

Det anbefales, at du ikke medbringer værdigenstande, smykker, penge o.lign., da disse ved bortkomst ikke erstattes af sygehuset.

Keyword indexing

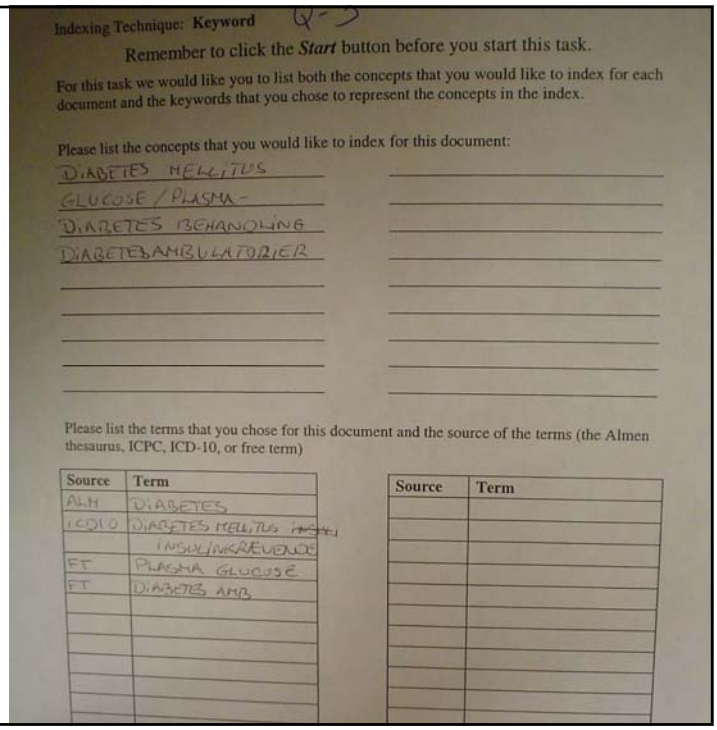

Indexing Technique: **Keyword** Q-3

Remember to click the ***Start*** button before you start this task.

For this task we would like you to list both the concepts that you would like to index for each document and the keywords that you chose to represent the concepts in the index.

Please list the concepts that you would like to index for this document:

DIABETES MELLITUS
GLUCOSE / PLASMA -
DIABETES BEHANDLING
DIABETESAMBULATORIER

Please list the terms that you chose for this document and the source of the terms (the Almen thesaurus, ICPC, ICD-10, or free term)

Source	Term
ALM	DIABETES
ICD10	DIABETES MELLITUS INSTE INSULINKRÆVENDE
FT	PLASMA GLUCOSE
FT	DIABETES AMB

Source	Term

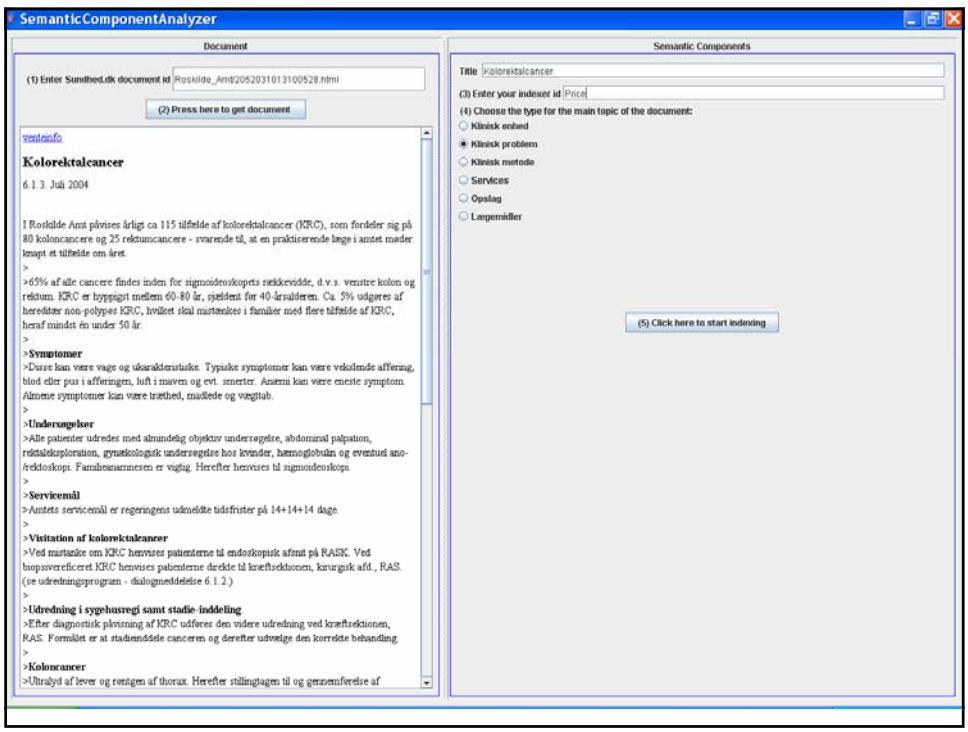

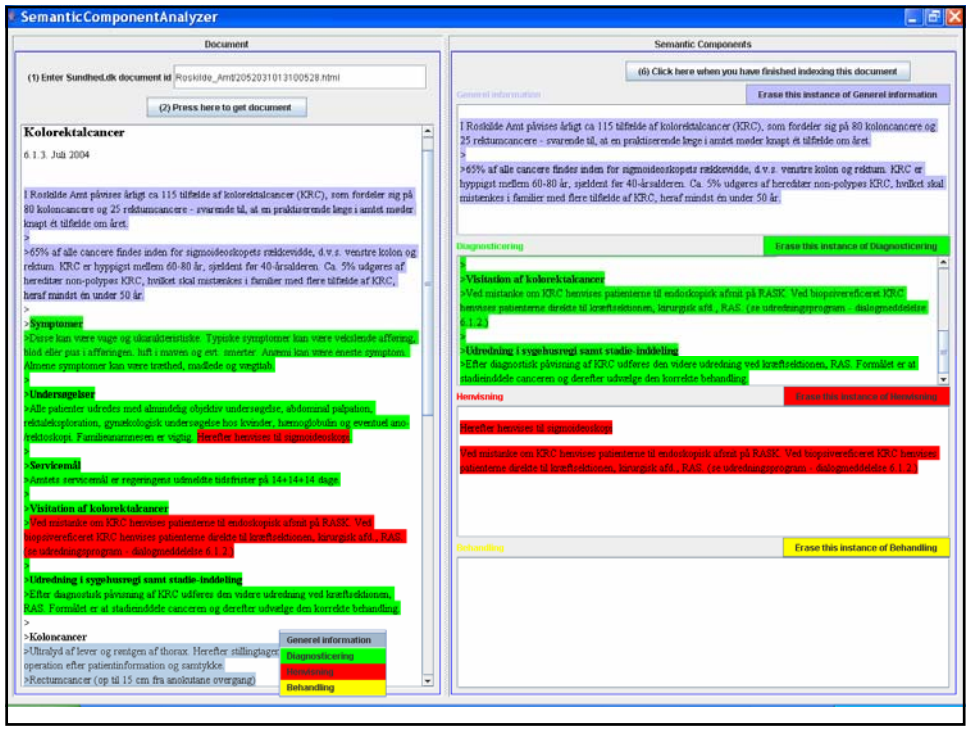

Indexing study results