

Л о г о



ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ В ОБРАБОТКЕ ТЕКСТОВ АВТОМАТИЧЕСКОЕ ЧТЕНИЕ ТЕКСТА



Система автоматического чтения текста (OCR- система – Optical Character Recognition).

— это компьютерная программа, позволяющая преобразовать текст с бумажного носителя в электронный текстовый файл, который может быть прочитан средствами обработки текстов.



Л о г о



Сканер

работает по принципу фотоаппарата, позволяя ПК «увидеть» текст. Для того чтобы «понять» его содержание, т.е. перевести графическое (точечное) изображение символов в пригодную для дальнейшей обработки (редактирования, рефериования, перевода и т.д.) текстовую форму, необходима система автоматического чтения текста



Л о г о

OCR- системы,
созданные российскими
разработчиками

FineReader
компании
«ABBYY Software
House»



CuneiForm
фирмы
«Congitive
Technologies»





возможности систем автоматического чтения текста огромны:

1

позволяют распознавать печатные символы почти двух сотен языков

2

хорошо распознаются рукопечатные символы, написанные от руки печатными буквами с небольшим интервалом между ними

3

узнают все используемые шрифты без предварительного обучения, воспринимают полужирный, курсивный, слипшийся текст

4

способны самообучаться и распознавать плохо пропечатанные символы или символы незнакомых программ языков



5

поддерживают все модели сканеров и любые графические форматы.

6

широко используются сетевые версии программ автоматического чтения текста

7

поддерживают публикацию бумажных документов в глобальной сети Интернет

8

точность распознавания OCR-систем на текстах хорошего и среднего качества достигает 97—99 %.



Logo

АВТОМАТИЧЕСКОЕ РЕФЕРИРОВАНИЕ И АННОТИРОВАНИЕ ТЕКСТА



Реферат — связный текст, который кратко выражает не только тему или предмет какого-либо документа, но и цель, применяемые методы, основные результаты описанного исследования или разработки.

Процесс составления реферата называется реферированием

Аннотация — краткое изложение содержания документа, дающее

общее представление о его теме.

Процесс составления аннотации называется аннотированием.



Logo



**Реферирование и аннотирование текста являются
довольно сложными и трудными видами
интеллектуальной деятельности и занимают много
времени.**



Лого

Выход есть!!!




Logo

Автоматическое рефериование и аннотирование



Logo

Этапы построения человеком реферата (аннотации)



референт определяет тематическую направленность текста и пытается понять и осмысливать документ в целом

текст делится на фрагменты (абзацы, аспекты и т.п.), в нем выделяют основные смысловые единицы (предложения, словосочетания, слова), составляется план аннотации (реферата)

выделенные ранее смысловые единицы (их комбинации или преобразования) располагаются в единый вторичный текст в соответствии с планом реферата или аннотации.


Компьютер должен уметь выполнять те же действия, которые осуществляет человек:

- 1 находить в тексте ключевые слова, словосочетания и предложения
- 2 находить в тексте менее значимые единицы
- 3 составлять из текстовых единиц двух первых типов смысловые единицы реферата или аннотации
- 4 составлять из таких единиц текст реферата или аннотации






Ключевое (опорное) слово — это термин, относящийся к основному содержанию текста и повторяющийся в нем несколько раз (с учетом всех возможных синонимов).



Ключевое словосочетание — это сочетание слов, среди которых есть одно или несколько ключевых.



Ключевое предложение - предложение, содержащее два и более ключевых слова или ключевых словосочетания.



Смысловые единицы реферата

1

полные (без изменения) ключевые предложения исходного текста;

2

перефразированные ключевые предложения исходного текста;

3

предложения, составленные из ключевых слов или словосочетаний исходного текста с помощью специальных связующих элементов;

4

предложения, обобщающие несколько предложений исходного текста (не обязательно ключевых).



Смысло́вые едини́цы аннота́ции

1

ключевые слова или словосочетания исходного текста с предшествующими им специальными фразами — реляторами типа: «В статье рассматриваются следующие вопросы:...», «Книга посвящена следующим проблемам: ...» и т.п.

2

специальные предложения, содержащие оценочные элементы: «Рассматривается важная проблема...», «Статья посвящена актуальной теме...» и т.д.;

3

специальные предложения, содержащие клише, т.е. специализированные словесные штампы, фиксирующие внимание читателя на определенных аспектах содержания: «Недостаток... заключается», «Цель публикации...», «Ставится задача...», «Делается попытка...» и т.д.


4

предложения, обобщающие несколько предложений исходного текста (не обязательно ключевых).



Logo

Методы автоматического реферирования



1) ключевыми словами считаются такие знаменательные слова текста, которые с учетом всех синонимов встречаются в тексте наибольшее число раз;
2) ключевым предложением считается предложение текста, которое:
а) имеет несколько ключевых слов;
б) содержит ключевые слова на небольшом расстоянии друг от друга.

ключевым предложением считается предложение, входящее в заголовок, подзаголовок, начало или конец какой-то части текста или всего текста. и содержат информацию о целях, методах, выводах и результатах исследования. Важность тех или иных предложений с указанной точки зрения определяется экспертами путем изучения семантической структуры первичных документов определенного типа.

опираются на исследование структуры и семантики текстов. Существует несколько вариантов этих методов, но цель их одна — выделить из конкретного текста предложения с наибольшим функциональным весом.



Л о г о

Системы автоматического реферирования

t

