

Системы оптического распознавания документов





Системы оптического распознавания символов

При создании электронных библиотек и архивов путем перевода книг и документов в цифровой компьютерный формат, при переходе предприятий от бумажного к электронному документообороту, при необходимости отредактировать полученный по факсу документ используются системы оптического распознавания символов.





Оптическое распознавание символов

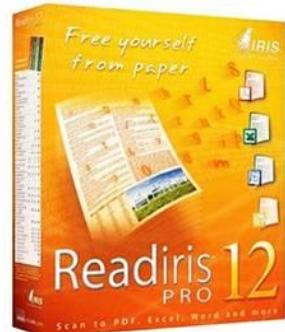
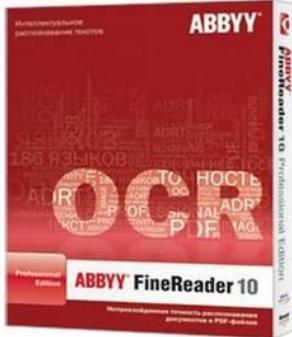
Оптическое распознавание символов

(англ. optical character recognition, OCR) — механический или электронный перевод изображений рукописного, машинописного или печатного текста в последовательность кодов, использующихся для представления в текстовом редакторе.

С помощью сканера несложно получить изображение страницы текста в графическом файле.



Программы распознавания текста



Free Online OCR

Преобразованием графического изображения в текст занимаются специальные программы распознавания текста (Optical Character Recognition - OCR).

Современная OCR должна уметь многое: распознавать тексты, набранные не только определенными шрифтами, но и самыми экзотическими, вплоть до рукописных. Уметь корректно работать с текстами, содержащими слова на нескольких языках, корректно распознавать таблицы. И самое главное — корректно распознавать не только четко набранные тексты, но и такие, качество которых, мягко говоря, далеко от идеала. Например, текст с пожелтевшей газетной вырезки или третьей машинописной копии. Само собой, распознать текст — это еще полдела. Не менее важно обеспечить возможность сохранения результата в файле популярного текстового (или табличного) формата — скажем, формата Microsoft Word.

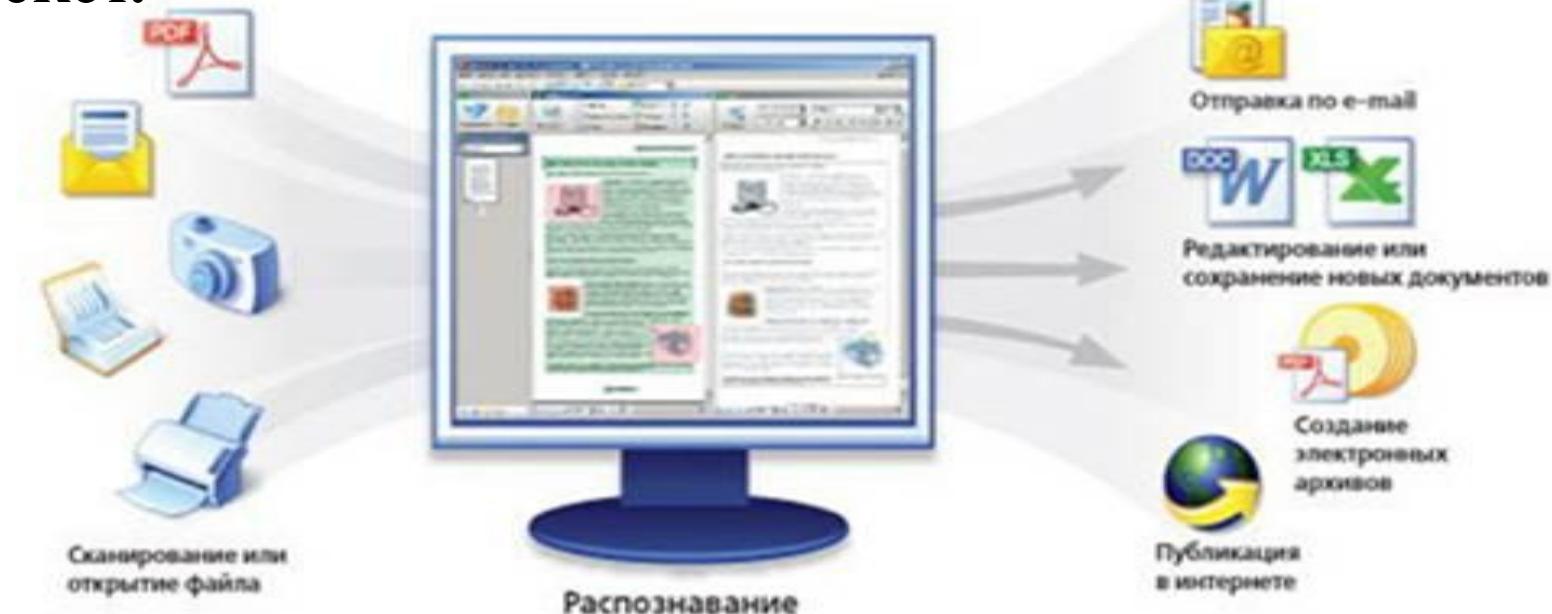


Однако для получения документа в формате текстового файла необходимо провести **распознавание текста**, т. е. преобразовать элементы графического изображения в последовательности текстовых символов.





- Сначала необходимо **распознать структуру** размещения текста на странице: выделить колонки, таблицы, изображения и т. д.
- Далее выделенные текстовые фрагменты графического изображения страницы необходимо **преобразовать в текст**.





Хорошее качество текста

Растровый метод распознавания текста

Если исходный документ имеет типографское качество (достаточно крупный шрифт, отсутствие плохо напечатанных символов или исправлений), то задача распознавания решается методом сравнения с растровым шаблоном.





Принцип работы сканера

Принцип работы сканера состоит в следующем: в результате преобразования света получается электрический сигнал, содержащий информацию об активности цвета в исходной точке сканируемого изображения. После оцифровки аналогового сигнала в АЦП цифровой сигнал через аппаратный интерфейс сканера идет в компьютер, где его получает и анализирует программа для работы со сканером. После окончания одного такого цикла (освещение оригинала — получение сигнала — преобразование сигнала — получение его программой) источник света и приемник светового отражения перемещается относительно оригинала.

ПРИНЦИП РАБОТЫ СКАНЕРА





Хорошее качество текста

Растровый метод распознавания текста

- Сначала растровое изображение страницы разделяется на изображения отдельных символов.
- Затем каждый из них последовательно накладывается на шаблоны символов, имеющихся в памяти системы, и выбирается шаблон с наименьшим количеством точек, отличных от входного изображения.

А Б В Ф Я



Хорошее качество текста

Растровый метод распознавания текста

- Растровое изображение каждого символа последовательно накладывается на растровые шаблоны символов, хранящиеся в памяти системы оптического распознавания. Результатом распознавания является символ, шаблон которого в наибольшей степени совпадает с изображением



Например, распознаваемый символ "Б" накладывается на растровые шаблоны символов (А, Б, В и т. д.)

Плохое качество текста



Структурный метод распознавания

- При распознавании документов с **низким** качеством печати (машинописный текст, факс и т.д.) используется **метод распознавания структурных элементов** (отрезков, колец, дуг и др.) символов. В искаженном символьном изображении выделяются характерные детали и сравниваются со **структурными шаблонами** символов.

И...Н

- Любой символ можно описать через набор параметров, определяющих взаимное расположение его элементов. Например, буква «Н» и буква «И» состоят из трех отрезков, два из которых расположены параллельно друг другу, а третий соединяет эти отрезки. Различие между буквами в величине улов, которые составляет третий отрезок с двумя другими.

Плохое качество текста



Структурный метод распознавания

При распознавании структурным методом в искаженном символьном изображении выделяются характерные детали и сравниваются со структурными шаблонами символов.

В результате выбирается тот символ, для которого совокупность всех структурных элементов и их расположение больше всего соответствуют распознаваемому символу.



Например, распознаваемый символ "Б" накладывается на векторные шаблоны символов (А, Б, В и т. д.)



Системы оптического распознавания форм

При проведении **Единого государственного экзамена**, при заполнении налоговых деклараций и т. д. используются различного вида бланки с полями. Рукописные тексты (данные вводятся в поля печатными буквами от руки) распознаются с помощью **систем оптического распознавания форм** и вносятся в компьютерные базы данных.

Сложность состоит в том, что необходимо распознавать символы, написанные от руки, а они довольно сильно различаются у разных людей. Кроме того, система должна определить, к какому полю относится распознаваемый текст.



Системы оптического распознавания форм

FineReader Forms

- **Бланком** называется стандартный лист бумаги, на котором размещается постоянная информация и отведено место для переменной.



Системы оптического распознавания форм

- Для обработки бланков предназначено специальное приложение **FineReader Forms**.
- Для распознавания содержимого бланка необходимо предварительно создать шаблон формы.

Сервис/ Шаблоны

- Шаблон используют на этапе сегментации. Сегментация в данном случае состоит в наложении шаблона.
- Положение шаблона корректируется в соответствии с тем, насколько ровно был размещён бланк при сканировании.
- Заключительный этап состоит в распознавании содержимого бланка.



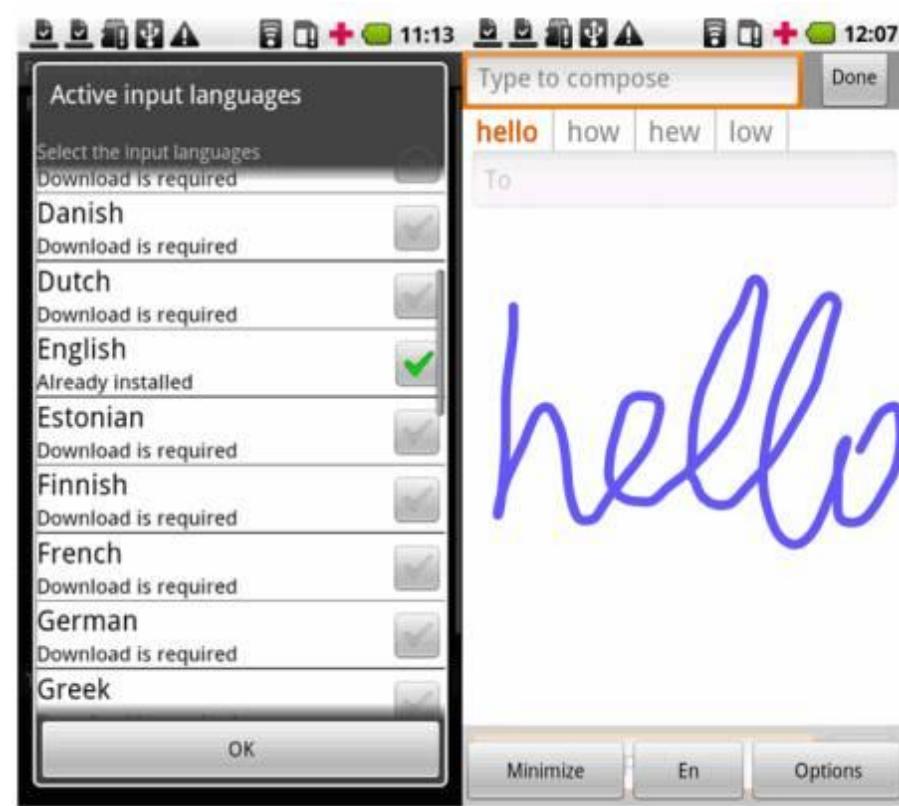
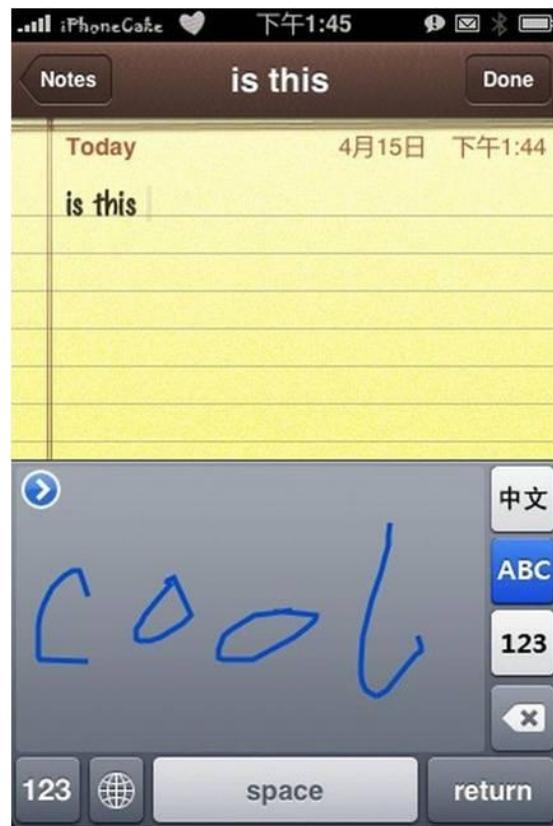
Системы распознавания рукописного текста

С появлением первого карманного компьютера Newton фирмы Apple в 1990 году начали создаваться системы распознавания рукописного текста. Такие системы преобразуют текст, написанный на экране карманного компьютера специальной ручкой, в текстовый компьютерный документ.





Системы распознавания рукописного текста



Программы оптического распознавания текста





Программы оптического распознавания документов

Для сканирования документов возможна работа с буфером обмена, сканером или камерой мобильного телефона. Программы распознавания символов.

Одной из наиболее известных программ такого типа является ABBYY FineReader.





OCR CUNEIFORM

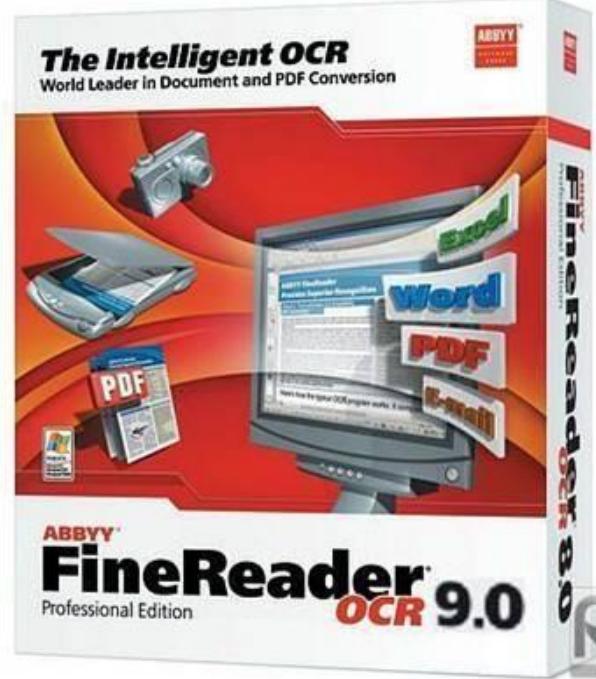
- Это **бесплатная** программа сканирования и распознавания текста российского разработчика Cognitive Technologies.
- **OCR Cuneiform** обеспечивает быстрое, удобное и качественное распознавание текста с сохранением исходного вида документа. Поддерживается распознавание с более 20 языков, среди них русский, украинский, английский, немецкий, французский, испанский, итальянский, португальский, шведский, финский, сербский, хорватский, польский, а также распознавание смешанного русско-английского текста.





ABBYY FineReader

- Популярная проприетарная программа распознавания текста компании ABBYY
- Программа производит распознавание текста около **180 языков**, для **38** из них предусмотрена встроенная проверка орфографии. Начиная с версии **Professional**, распознаются иврит, японский, тайский, китайский языки. Finereader открывает файлы графических форматов (TIFF, JPG, PDF, PNG и др.) в том числе **DjVu** – компактный формат для хранения отсканированных документов, книг.





Окно программы FineReader

Стиль меню

Панели инструментов

Текущий пакет страниц

Блокчайна структура текста

Результат распознавания

Default - ABBYY FineReader 5.0 Office Try&Buy - [1 - Text]

Файл Правка Вид Пакет Изображение Процесс Сервис Окна Справка

Scan&Read Сканировать Распознать Проверить Сохранить

17

1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17

Русский

а русского языка — примерно в 7 раз. В
мо, поэтому в Office XP русский язык
не поддерживается. Второй момент, на
кий указывают специалисты ABBYY, за
чается в том, что ScanSoft предлагает та
логию распознавания текстов, в то врем
перед современными OCR ставится за
распознавания не просто текста, а доку
та, который содержит элементы формат
вания: внедренные картинки, а иногда и
фоновые картинки. Разница в слож
этих задач существенна, и то, что позво
делать FineReader по распознаванию д

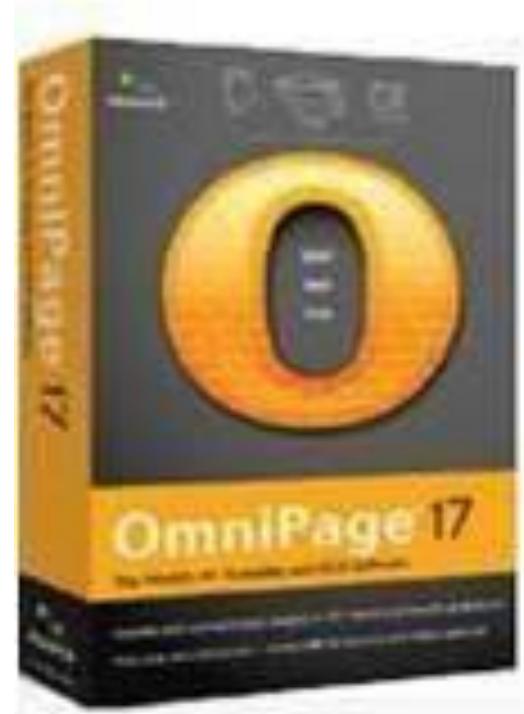


Процесс обработки FineReader

- Сканирование (сканер, цифровой фотоаппарат, цифровая видеокамера).
- Сегментация - выделение блоков на изображении.
- Распознавание – неоднозначно опознанные символы выделяются цветом.
- Проверка ошибок- можно провести проверку грамматики.
- Сохранение результатов в виде отформатированного или неотформатированного документа, или прямой передачи в другое приложение - WORD, Excel в буфер обмена Windows.

➡ OmniPage

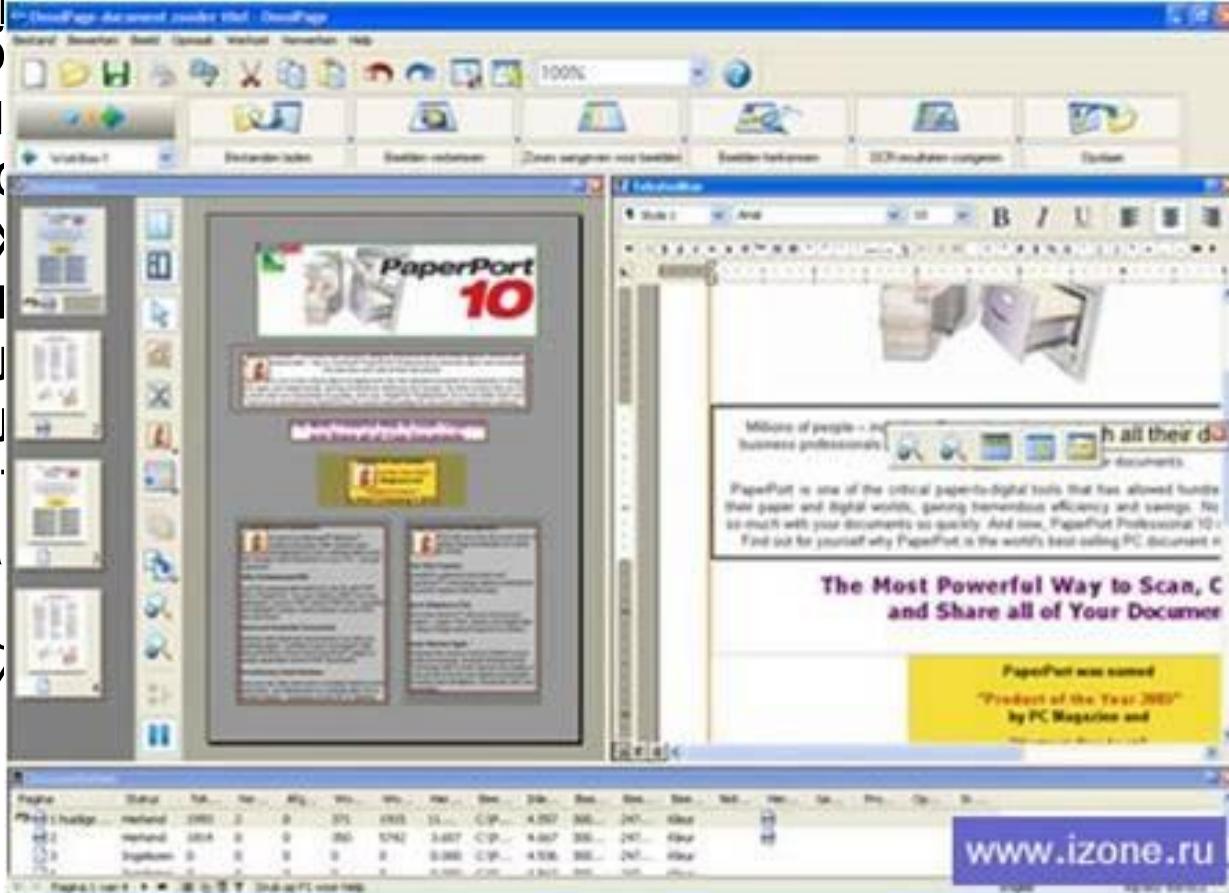
- Популярная программа распознавания текста **российской компании ABBYY**
- Программа отличается высокой скоростью и точностью распознавания. Распознаются более **120** языков с различными алфавитами: **латинский, греческий алфавиты, кириллица, китайский, японский и корейский языки.** Как и FineReader, OmniPage уверенно распознает документы, полученные с помощью цифровых камер с помощью технологии коррекции изображения "3D Correction".





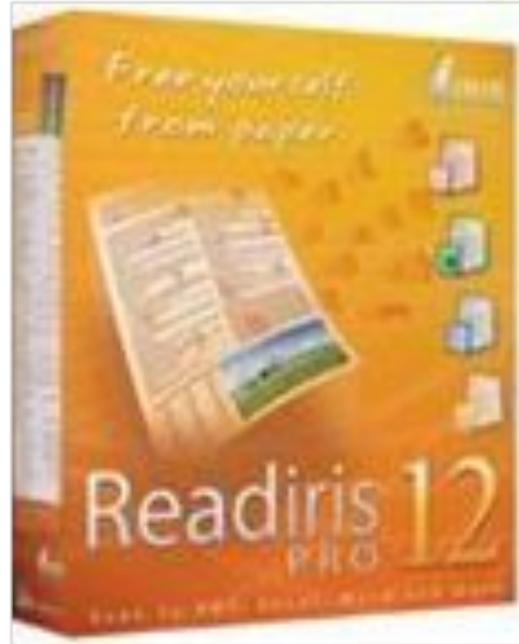
OmniPage

- В программе присутствуют удобные инструменты обработки изображений, повышенное качество сканирования без повторного сканирования; функция преобразования документов в PDF, возможность работы с Google документами (и т.д.). В PaperPort имеется функция конвертации изображений в PDF. Важно отметить, что PaperPort имеет встроенный редактор для создания и редактирования PDF-документов.



Readiris

- Программа сканирования и распознавания текста **компании I.R.I.S.**
- Поддерживается распознавание текста с более **120 языков** распознавания, включая русский, а также ближневосточные языки - **арабский, иврит, фарси** (в версии Middle-East) и **японский, китайский, корейский** (в версии Asian). Есть версия Readiris для **Macintosh**.
- Вместе с поддержкой распознавания популярных форматов картинок, распознаются файлы **PDF** и **DjVu**.





Readiris



Содержит региональные пакеты для распознавания азиатских языков и языков среднего востока.



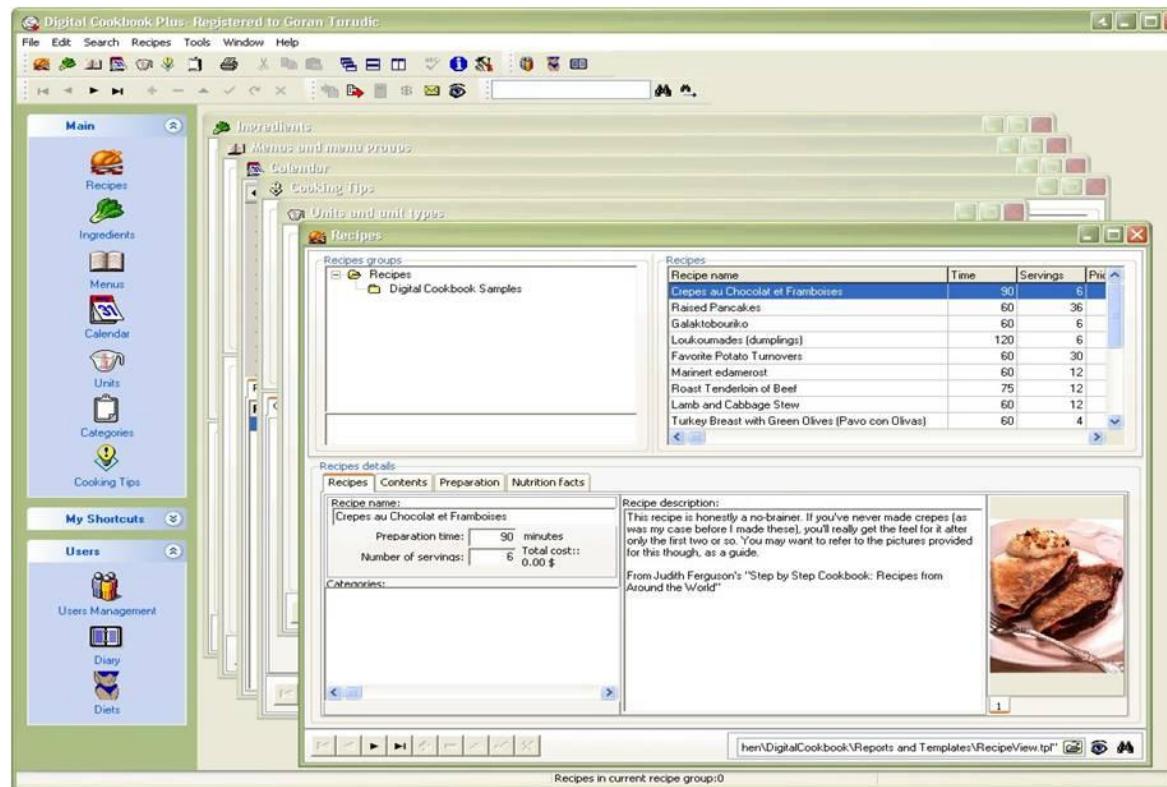
Kirtas Technologies

Arabic OCR

Может распознавать арабские и английские символы на одной странице.



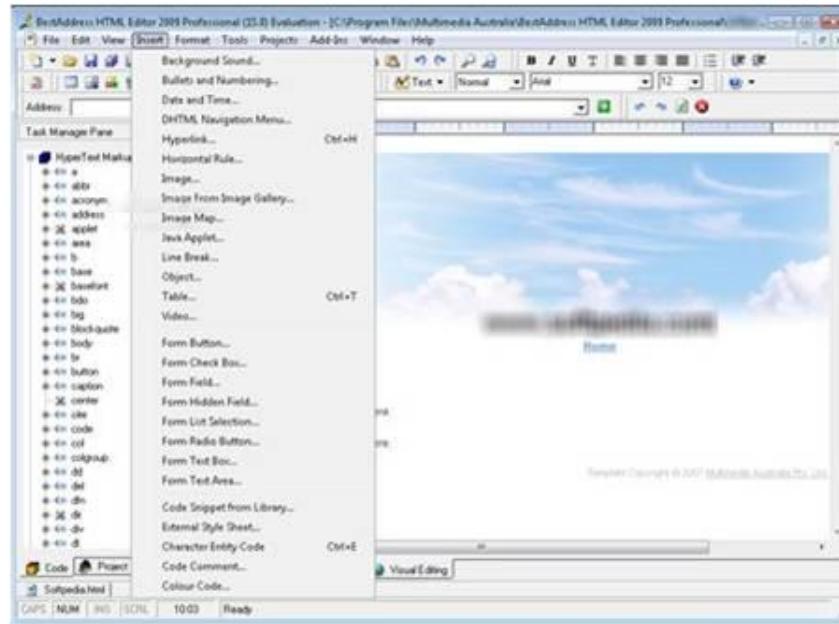
Zonal OCR



Помогает автоматизировать извлечение
данных из компьютерных изображений.



Brainware



Извлечение данных из документов и их обработка — например, счета, извещения, накладные и платёжки



Microsoft Office Document Imaging

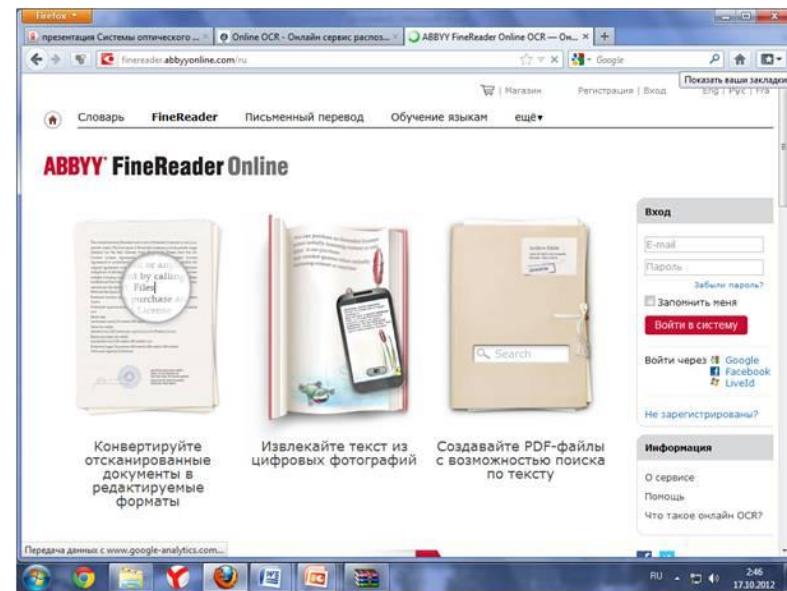
- Программа распознавания текста компании **Microsoft**
- Программа Document Imaging способна работать только с **двумя языками**: английским и языком локализации самого MS Office. Для поддержки других языков необходимо дополнительно устанавливать пакет **Multilingual User Interface (MUI)**. **OCR** настроек в программе практически нет, программа в автоматическом режиме поддерживает распознавание типа и размера шрифтов, картинок и простых таблиц.



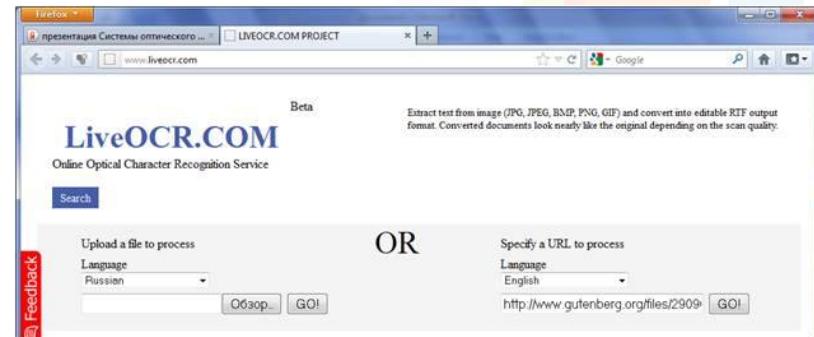
Существует также системы On-line распознавания текста: **Online OCR** и **ABBYY FineReader Online** (<http://www.onlineocr.ru> , <http://finereader.abbyyonline.com>, <http://www.liveocr.com/>)



The screenshot shows the homepage of OnlineOCR.ru. At the top, there's a logo with the text "ONLINE OCR". Below it, a navigation bar includes "Войти" (Login), "Главная" (Home), "Кабинет" (Cabinet), and "Контакты" (Contacts). A central banner says "Online Сервис Распознавания Текста". To the left, there's a sidebar with "Новая услуга!" (New service!) and "OCR Web Service" sections. The main content area has sections for "Распознать" (Recognize), "Конвертировать" (Convert), and "Хранить" (Store). It also features a "Upload" button and a small illustration of a character holding a pen.



The screenshot shows the homepage of ABBYY FineReader Online. It features a large banner with the text "ABBYY FineReader Online". Below it, there are three main sections: "Конвертируйте отсканированные документы в редактируемые форматы" (Convert scanned documents into editable formats), "Извлекайте текст из цифровых фотографий" (Extract text from digital photos), and "Создавайте PDF-файлы с возможностью поиска по тексту" (Create PDF files with text search). The right side of the page includes a login form, social media links, and an "Information" section.



The screenshot shows the homepage of LiveOCR.COM. It has a "Beta" status indicator. The main heading is "LiveOCR.COM" with the subtitle "Online Optical Character Recognition Service". Below this, there are two main input fields: "Upload a file to process" and "Specify a URL to process". Both fields have dropdown menus for "Language" set to "Russian" and "English". Buttons for "Обзор..." (Browse...) and "GO!" are next to each input field. A "Feedback" link is located at the bottom left.



Подведение итогов урока

1. В чем состоят различия в технологии распознавания текста при использовании растрового и векторного методов?
2. Для чего предназначены программы оптического распознавания документов?