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.

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.**

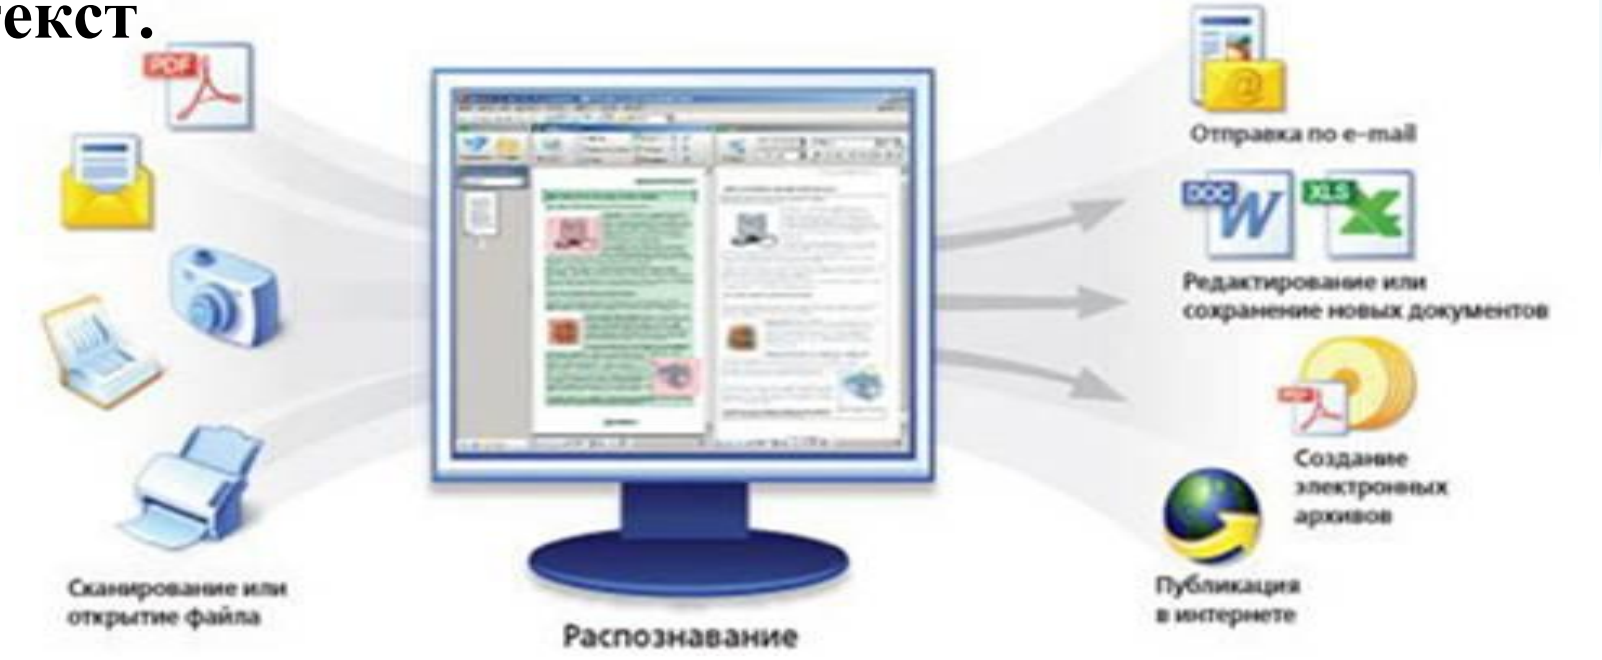

Хорошее качество текста

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.

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.

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.

- 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

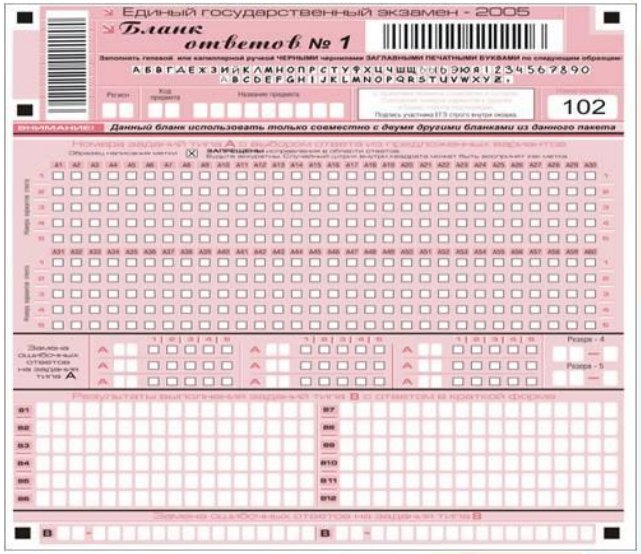

- ***Бланком*** называется стандартный лист бумаги, на котором размещается постоянная информация и отведено место для переменной.
- Сложность состоит в том, что необходимо распознать написанные от руки символы, довольно сильно различающиеся у разных людей.
- Кроме того система должна определить, к какому полю относится распознаваемый текст.

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

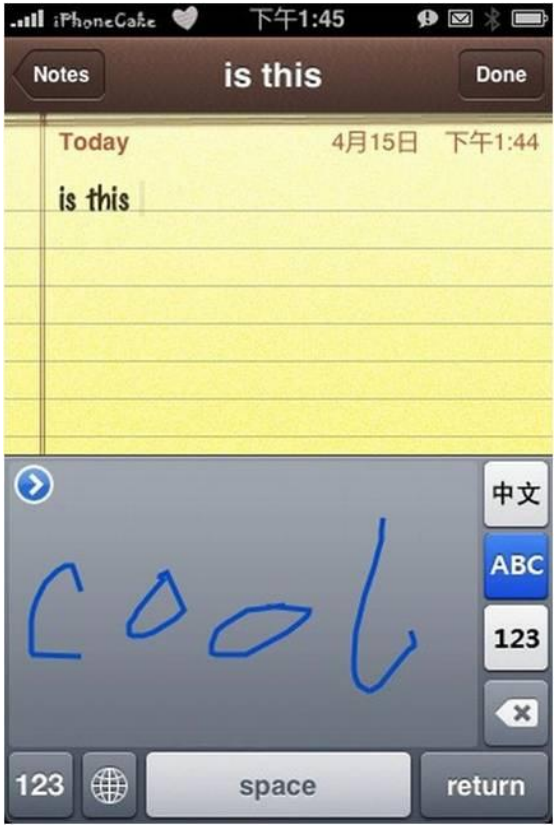

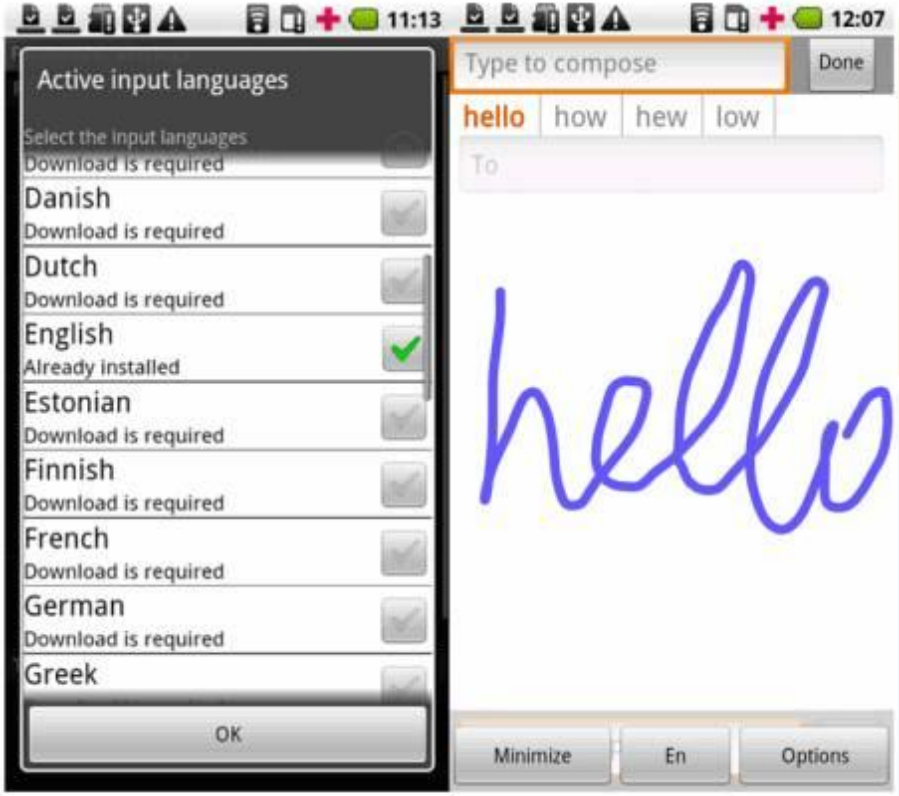

Программы оптического распознавания текста

Программы оптического распознавания документов

Для ввода текстов в память компьютера с бумажных носителей используют **сканеры** и цифровые фотоаппараты или камеры мобильных телефонов. Для этого применяют **программы распознавания символов**.

Одной из наиболее [illegible] программ такого типа является ABBYY Fine[illegible]

Отсканированные документы

Работа с программой распознавания текста

Фотографии текстов

[illegible]мажный носитель помещается на крышку

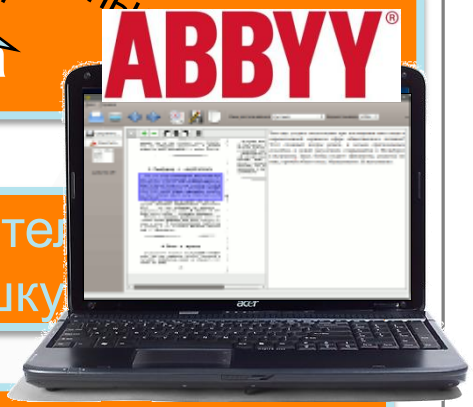

В программе отдаётся команда [illegible]вать и распознать

Распознанный текст переносится [illegible] редактора

Сканеры.swf

Оптическое распознавание документов

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
оригинал
стекло
отражённый луч
приёмник света
источник света
преобразователь
преобразование света
в электронный сигнал
в компьютер

Программы распознавания текста

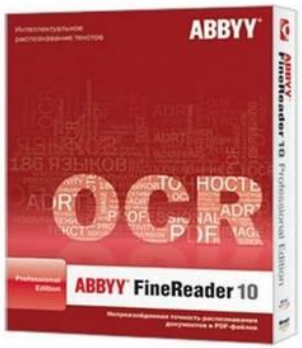

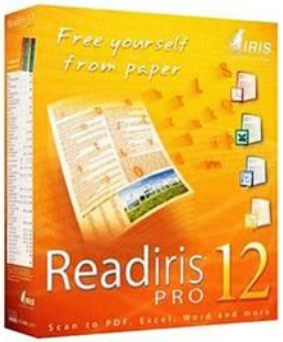

Преобразованием графического изображения в текст занимаются специальные программы распознавания текста (Optical Character Recognition - OCR).

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.

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 с более **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, PFD, PNG и др.) в том числе **DjVu** – компактный формат для хранения отсканированных документов, книг.

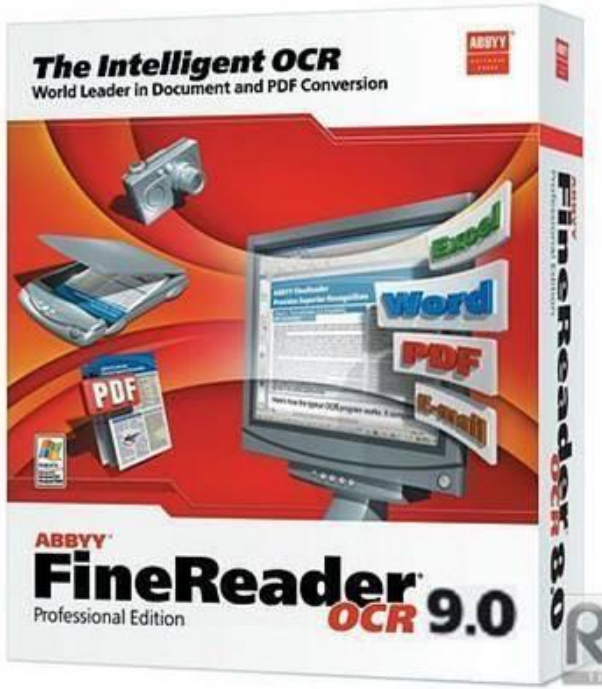

Окно программы FineReader

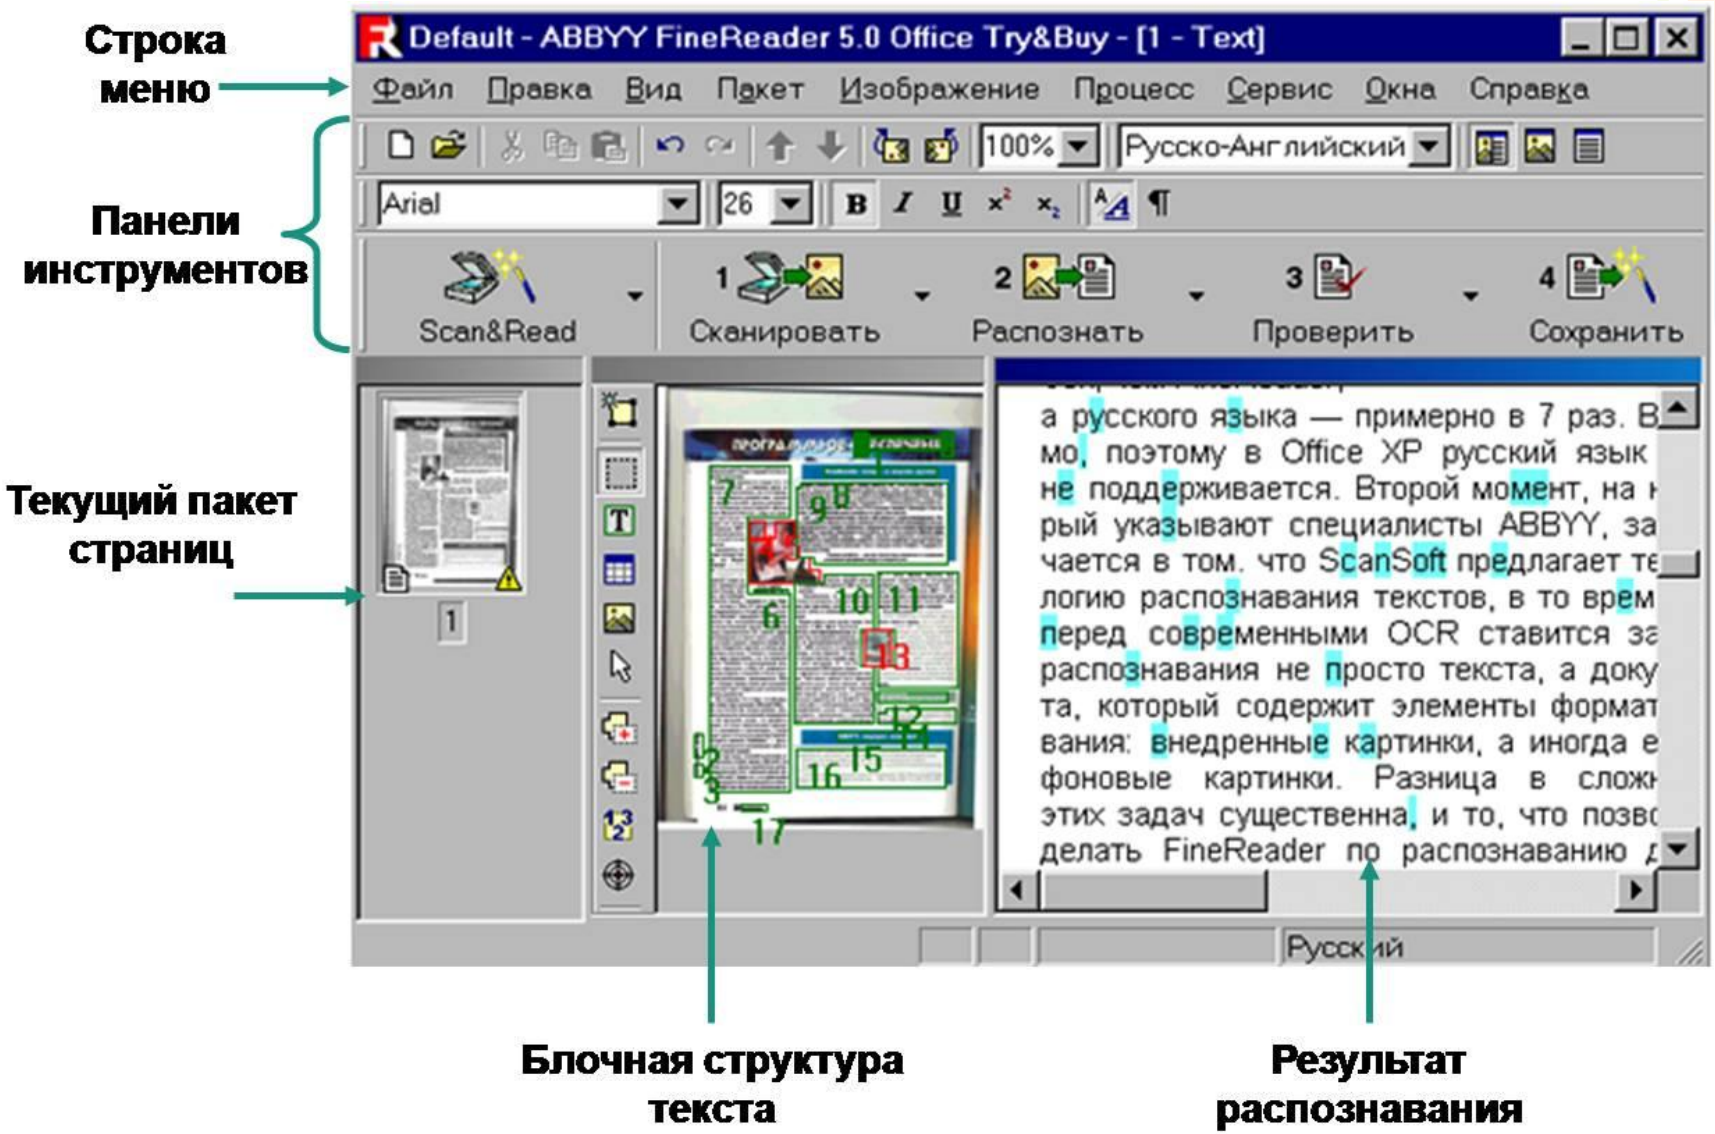

Процесс обработки FineReader

- 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 преоб е докум Google Deskt айла (и други м. В компл ся несколь Converter - позв PDF в редак ощенный вариа ет обрат чески любой мат PDF.

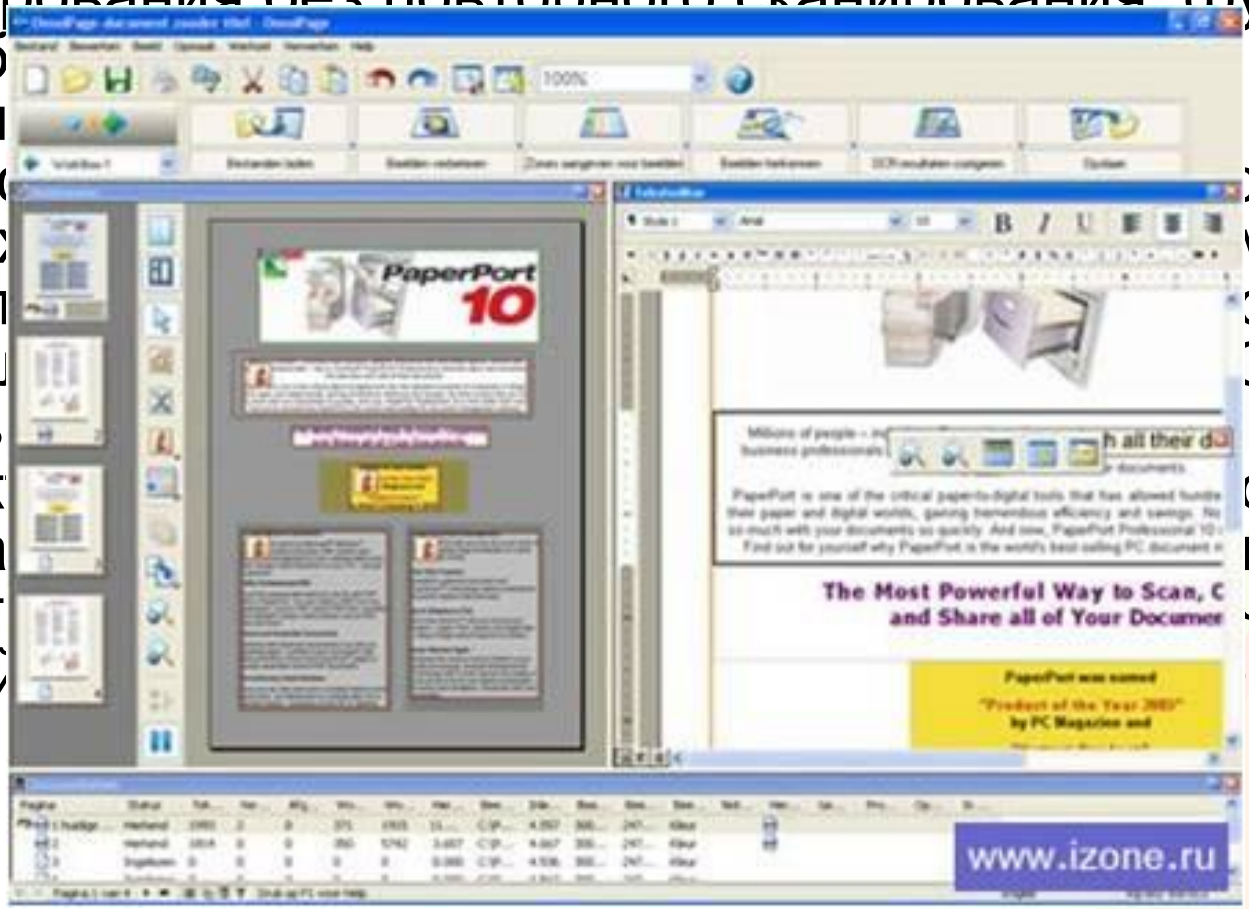

Readiris

- 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**.

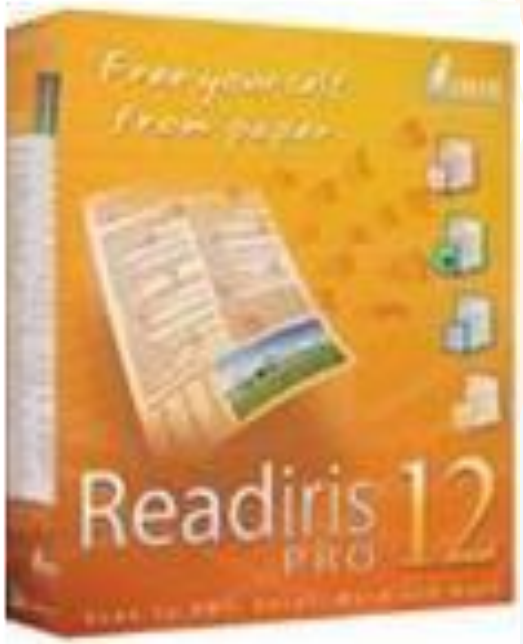

Readiris

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

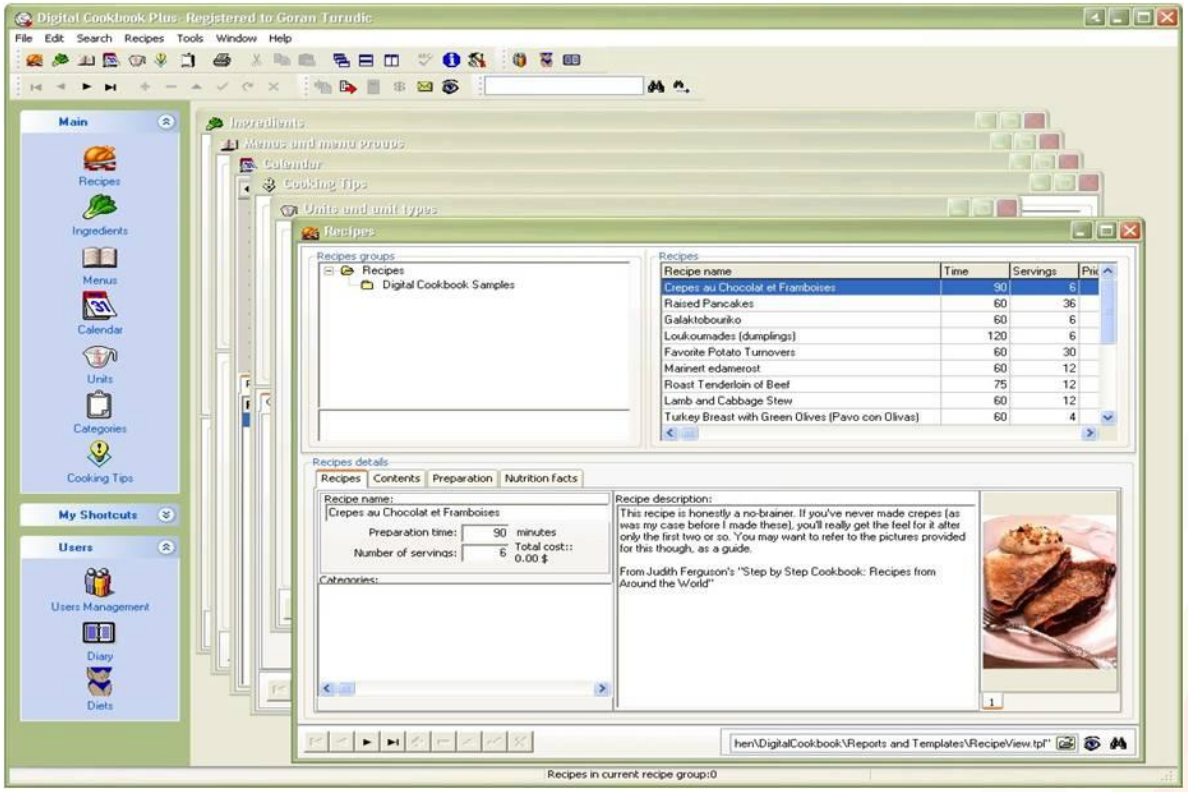

Помогает автоматизировать извлечение данных из компьютерных изображений.

Brainware

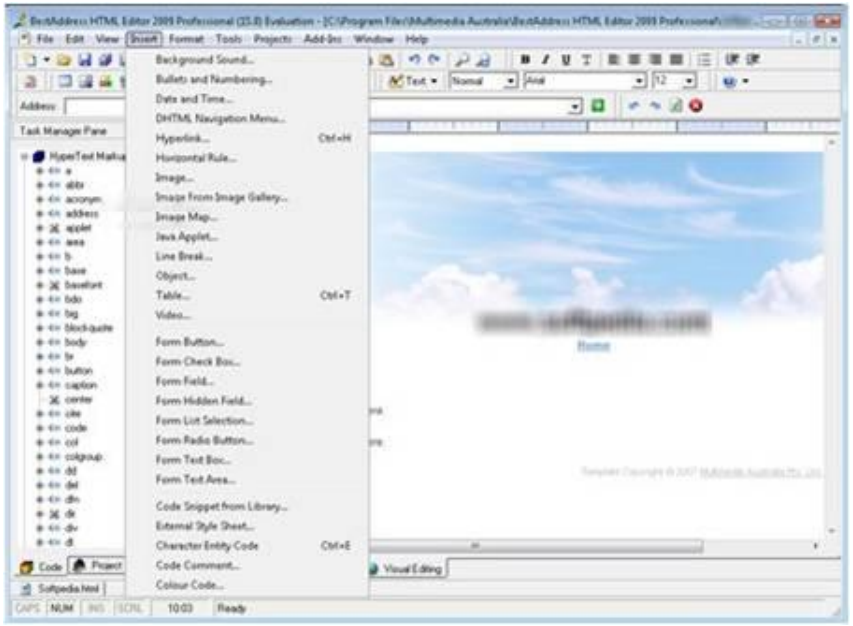

Извлечение данных из документов и их обработка — например, счета, извещения, накладные и платёжки

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/)

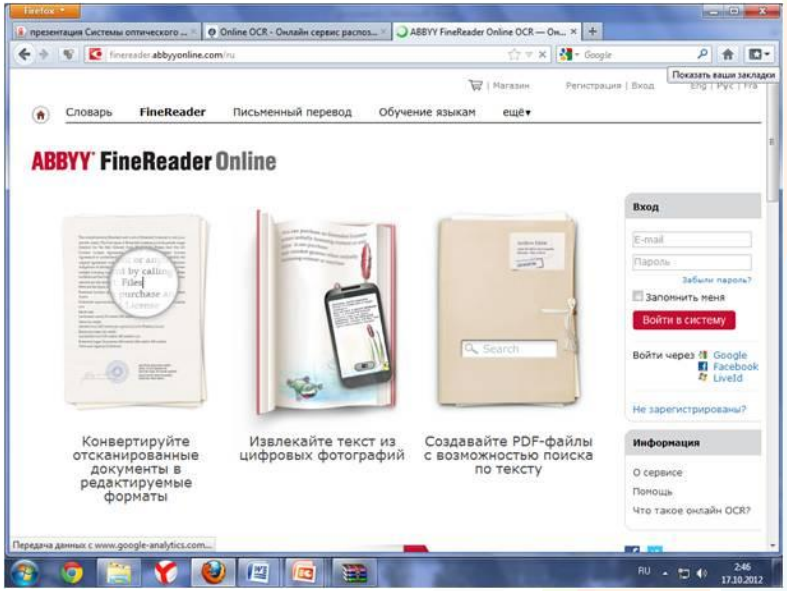

ЗАДАНИЕ

1) Распознать на сайте https://www.ilovepdf.com/ru

(Айлав пдф) прикрепленный документ пдф, перевести его в формат WORD, переименовать его, дать имя:

ДАТА КЛАСС ФАМИЛИЯ Распознанный

И прислать его в элжур или показать учителю

2) Решить задачи для самостоятельного решения из файла 6 штук в тетради!

Отправить фотографии тетради учителю в элжур с решением! Пишите ТЕМУ и ДАТУ

На КАЖДОЙ странице рядом с номером пишем ФАМИЛИЮ