

# DOCUMENT IMAGE COMPRESSION

by Dave Tompkins  
 MASc. Candidate -- dave@ece.ubc.ca  
 Supervisor -- Dr. Faouzi Kossentini

## Our Project:


We are researching and developing advanced strategies for compressing image documents. Applications for our research include fax machines, archival systems, and Internet document systems. The framework for our research is the JBIG-2 standard.

**JBIG-2:** JBIG - the Joint Bi-level Image Expert Group (bi-level means black & white) is an international committee comprised of industry and academic members, who have developed the standard. The standard only defines the framework and core technologies, leaving many of the compression strategies up to the people implementing the standard.

*UBC is an active member of the JBIG committee, and some elements of the JBIG-2 standard have resulted from our research. We are also the first group to implement a full-featured JBIG-2 coder, and the public-domain software was written by us.*

Compare our results with some of the other available formats. If you wanted to send someone a fax by e-mail, which format would you use?

le phasé des fichiers nécessaires aux applications diffèrent, le nombre d'images est donc soit à leur encontre, soit, par exemple, celui de fichiers des représentations. Le fichier de base est donc un quantifié de représentations d'images de caractères à gérer en phase avec l'envoi de données à l'écran et au terminal. Les images sont donc représentées par des fichiers binaires de données, sans avoir pu permettre la progressive de toutes les applications, malgré les informations sur véritable "langage de données" national et régional, et qui doivent être traités de la base de l'entreprise, c'est-à-dire les services d'abonnement, les services de courrier électronique et les services de données. Les fichiers de données sont donc constitués à partir de fichiers binaires de données, sans avoir pu permettre la progressive de toutes les applications, malgré les informations sur véritable "langage de données" national et régional, et qui doivent être traités de la base de l'entreprise, c'est-à-dire les services d'abonnement, les services de courrier électronique et les services de données. Les fichiers de données sont donc constitués à partir de fichiers binaires de données, sans avoir pu permettre la progressive de toutes les applications, malgré les informations sur véritable "langage de données" national et régional, et qui doivent être traités de la base de l'entreprise, c'est-à-dire les services d'abonnement, les services de courrier électronique et les services de données.



BMP	1:1
GIF	4.1:1
ZIP	5.4:1
FAX	7.8:1
UBC	14.9:1

BMP	1:1
FAX	1:1
GIF	24:1
ZIP	3.5:1
UBC	7.4:1

## Our Strategies:

### 1 SEGMENTATION

Text, graphics, and pictures all compress differently. By *segmenting* the image, we can use a different algorithm for each type.



*We have developed advanced techniques to quickly separate documents into text, line-art and pictures to improve both speed and compression.*

### 2 DICTIONARIES

In any language, certain patterns of letters (such as the word "the") will occur more often than others. We can exploit this to achieve higher compression. This is called a *dictionary* strategy.



*We are researching advanced dictionary techniques, including language-independent dictionaries that span across several pages of a document.*

### 3 REFINEMENT

When documents are scanned or faxed, small errors are introduced so that identical letters are no longer identical. With *refinement* coding, we can adapt, so that compression increases with each subsequent letter.



*We are developing pattern recognition techniques that will determine when refinement coding should be used, and how it should be implemented.*

### 4 FILTERING

By *filtering* the document and making subtle changes that are hardly noticeable to the human eye, we can significantly improve the compression performance.



*We are exploring numerous filtering strategies that achieve extremely high compression rates, without significantly distorting the image.*

This Project is Sponsored by:

