Trabalho de Formatura Supervisionado

Aplicação de análise morfológica para segmentação de páginas em imagens de documentos

Ricardo de Cillo

Supervisora: Nina S. T. Hirata

Departamento de Ciência da Computação
Intituto de Matemática e Estatística, IME-USP

Resumo: Neste texto apresentamos nosso estudo sobre a aplicação de operadores morfológicos à segmentação de páginas de documentos, etapa importante na análise de documentos que busca extrair informações sobre a sua estrutura: regiões com títulos, legendas, figuras e blocos de texto.

São Paulo, 11 de fevereiro de 2013

Sumário

1 Introdução **1**

2 Fundamentos **3**
2.1 Imagens digitais . . . 3
2.2 Operadores de imagens . . . 3
2.2.1 Operadores morfológicos binário . . . 3
2.2.2 Operadores localmente definidos e invariantes por translação . . . 3
2.3 Classificação de objetos . . . 4
2.4 Segmentação de imagens . . . 4
2.5 Classificação dos componentes . . . 4

3 Operadores morfológicos automaticamente gerados **6**
3.1 Formalização . . . 6
3.2 Coleta . . . 6
3.3 Decisão . . . 7
3.4 Minimização . . . 7

4 Metodologia **8**
4.1 Preparação das imagens de treinamento . . . 8
4.2 Construção dos operadores . . . 8
4.3 Aplicação dos operadores . . . 8
4.4 Consensualização . . . 9

5 Experimentos **10**
5.1 Base de dados . . . 10
5.2 Mistura de publicações no conjunto de treinamento . . . 10
5.3 Tipos de regiões . . . 11
5.4 Quantidade de imagens de treinamento . . . 11
5.5 Formatos de janelas . . . 12
5.6 Tamanho da janela de consensualização . . . 12
5.7 Aplicação . . . 12
5.8 Avaliação da segmentação . . . 12

6 Resultados **13**
6.1 Valores observados . . . 14
6.2 Imagens finais . . . 29

7 Conclusão **35**

8 Apêndice **35**
8.1 Algoritmo de Otsu para binarização . . . 35
8.2 Implementação . . . 36

1 Introdução

Processamento e análise de documentos é uma importante subárea da área de reconhecimento de padrões cujo principal objetivo é a interpretação de um documento, ou seja, o entendimento da sua estrutura bem como o reconhecimento de cada um dos componentes estruturais.

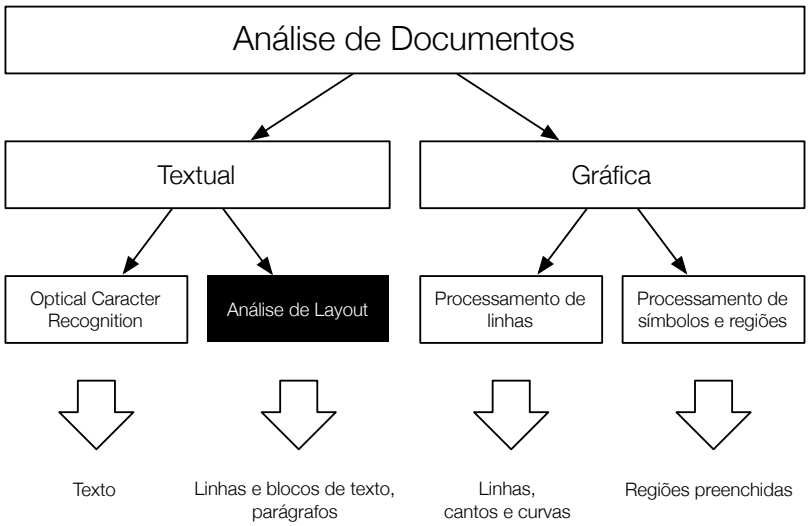

Figura 1: Contextualização do tema do trabalho entre as áreas da análise de documentos. Adaptado de [1].

Segmentação de página refere-se à tarefa de separar e rotular os diferentes componentes que fazem parte da estrutura das páginas de um documento, tais como: blocos de texto, gráficos, figuras, títulos, legendas, separadores, tabelas, fórmulas matemáticas e regiões com ruído.

Em geral, a segmentação de página é um dos primeiros passos no processo de entendimento de um documento. Uma vez identificados os blocos estruturais, processamentos específicos para cada tipo de bloco podem ser aplicados. Por exemplo, no caso de blocos de textos é conveniente fazer o reconhecimento de texto para que o mesmo possa ser armazenado em formato texto (e não imagem). Por outro lado, no caso de imagens, pode ser interessante armazená-las em alta resolução para manter a qualidade. Documentos digitalizados podem ser processados eficientemente em processos que envolvem armazenamento, edição, transmissão, ou busca, por exemplo.

Devido a grande quantidade de documentos, é interessante que o seu processamento seja realizado de forma automatizada ou pelo menos semi-automatizada. Para tal, diversas soluções computacionais vêm sendo propostas para o problema ao longo dos anos desde o surgimento desse campo de pesquisa. Automatizar esta tarefa reduz custos, aumenta a velocidade e capacidade de processamento de documentos além de possivelmente reduzir a taxa de erro humano na classificação de uma região.

Neste trabalho exploraremos a aplicabilidade de operadores morfológicos automaticamente gerados ao problema de segmentação de páginas.

Este texto está organizado da seguinte forma. Na seção 2, apresentamos as definições e conceitos básicos que serão importantes para a leitura deste texto. Na seção 3 explicamos com maior profundidade a principal ferramenta utilizada para realizar a segmentação: operadores morfológicos automaticamente gerados. Na seção 4 apresentamos como utilizamos todos os

conceitos para resolver o problema. Na seções 5 e 6 detalhamos os experimentos e apresentamos os resultados. Finalmente na seção 7 fazemos a conclusão do trabalho.

2 Fundamentos

2.1 Imagens digitais

Uma imagem digital monocromática pode ser definida como uma função $f : E \subset \mathbb{Z}^2 \to K = \{0, 1, \ldots, k-1\}$, na qual k representa o número de tons de cinza. Tipicamente adota-se $k = 256$, ou seja, 8-bits de cor. Quando $k = 1$ as imagens são denominadas **binárias**; quando $k > 1$ as imagens são denominadas **tons de cinza**. Na prática, o domínio E é um retângulo finito de dimensões $m \times n$ (uma matriz de m linhas e n colunas).

Uma imagem RGB (colorida) é uma função $f : E \to K^3$, onde cada componente K representa a intensidade das cores vermelho, verde e azul, respectivamente.

2.2 Operadores de imagens

Um operador de imagens é uma função que mapeia imagens em imagens. Denotando $E = \mathbb{Z}^2$, $K = \{0, 1, \ldots, k-1\}$ e todas as imagens definidas em E por K^E, podemos representar um operador de imagens como $\Psi : K^E \to K^E$.

2.2.1 Operadores morfológicos binário

Uma função $f \in \{0,1\}^E$ pode ser vista como indicadora de um conjunto $S_f \subseteq E$, ou seja, para todo $x \in E$, $x \in S_f \Leftrightarrow f(x) = 1$. Desta forma, uma função binária pode ser vista como um conjunto. Uma função entre imagens pode ser vista como uma função entre conjuntos. Conjuntos adicionados da relação de inclusão constituem algebricamente um reticulado booleano. Operadores morfológicos binários são operadores vistos como mapeamentos entre reticulados booleanos.

2.2.2 Operadores localmente definidos e invariantes por translação

Duas classes de operadores são importantes para o entendimento de operadores automaticamente gerados: localmente definidos e invariantes por translação.

Sejam x e y pertencentes a E, $x+y$ denota a soma vetorial em E. Dado um conjunto $X \subseteq E$, $X_z = \{x + z \colon x \in X\}$ denota a translação de X por z

Seja $W \subseteq E$, chamado de janela ou elemento estruturante, um operador Ψ é dito localmente definido em relação a W, para todo $X \subseteq E$, se,

$$[\Psi(X)](x) = [\Psi(X \cap W_x)](x). \tag{1}$$

Operadores localmente definidos podem ser caracterizados por funções locais [2]. Ou seja, independentemente to tamanho do conjunto X, $\Psi(X)$ pode ser visto como uma função booleana $\psi_x \colon \{0,1\}^n \to \{0,1\}$, onde $n = |W|$, da seguinte forma:

$$[\Psi(X)](x) = \psi_x(X_{-x} \cap W), \tag{2}$$

onde $X_{-x} \cap W$ denota a atribuição de valores de $x \in X$ às variáveis x_i da função booleana, de acordo com a regra $x_i = 1 \Leftrightarrow w_i \in X_{-z} \cap W$, ou equivalentemente, se $w_i + z \in X$.

Se Ψ também for invariante por translação então teremos $\psi_x = \psi_y$ para $x, y \in E$. Operadores localmente definidos e invariantes por translação são chamados de W-operadores, operadores de janela.

Alguns exemplos de operadores desta classe são dilatação (3) e erosão (4), ditos operadores elementares.

$$\delta_B(X) = \{x \in E \colon B_x \cap X \neq \emptyset\} \tag{3}$$

$$\varepsilon_B(X) = \{x \in E \colon B_x \subseteq E\} \tag{4}$$

2.3 Classificação de objetos

Na área de reconhecimento de padrões e aprendizado computacional estudam-se métodos e técnicas para classificação de dados em geral. Os dados (padrões) a serem classificados correspondem, em geral, à representação digital de algum objeto concreto ou abstrato. O objetivo da classificação é atribuir um rótulo de classe a cada padrão observado.

Dependendo do problema, os rótulos de classe podem ser conhecidos ou não. Por exemplo, se desejamos fazer o reconhecimento de caracteres, os padrões são a imagem dos caracteres e os rótulos de classe são as identificações dos possíveis caracteres. Por outro lado, em problemas como na classificação de perfil de consumidores, pode não haver um conjunto de perfis pré-estabelecidos e o objetivo seria então identificar a possível existência de perfis. O primeiro é conhecido como problema de classificação supervisionada e o segundo como classificação não-supervisionada.

No caso da classificação supervisionada, supõe-se que os padrões são elementos de um espaço X e que o conjunto de rótulo de classe é dado por $Y = \{y_1, y_2, \ldots, y_c\}$. Assim, um classificador pode ser expresso por uma função $f : X \to Y$.

Frequentemente X é um subespaço de $\mathbb{R}^d$. Assim, um padrão é representado por uma d-upla $\mathbf{x} = (x_1, x_2, \ldots, x_d) \in \mathbb{R}^d$.

2.4 Segmentação de imagens

A segmentação de imagens é um processamento comum a praticamente todos os processos que envolvem análise de imagens. Segmentar uma imagem corresponde a particionar o seu domínio, de forma que cada região resultante corresponda (do ponto de vista semântico) a uma componente de interesse na análise em questão. Este problema pode ser modelado como uma classificação de objetos, onde o conjunto de pixeis de uma imagem são os objetos em X e as componentes em Y são regiões de interesse.

2.5 Classificação dos componentes

O problema de segmentação de imagens de documentos pode ser modelado como um problema de classificação de objetos, onde cada pixel da imagem é rotulado através de uma função classificadora

$$\Psi \colon \mathbb{E} \to \mathbb{Y} \tag{5}$$

sendo $\mathbb{Y}$ um conjunto composto pelas regiões de interesse:

- blocos de texto: região com parágrafos
- gráficos
- figuras
- títulos
- legendas

- separadores
- tabelas
- fórmulas matemáticas
- regiões com ruído

Neste trabalho utilizaremos operadores morfológicos binários como classificadores de imagens. O processo todo será descrito na seção 4.

3 Operadores morfológicos automaticamente gerados

Construir operadores morfológicos que resolvam problemas complexos como o de segmentar uma página de documento, pode ser uma tarefa que demande muito tempo, experiência e conhecimento específico do assunto. Como estas imagens possuem características distintas dependendo da publicação (diferentes jornais e revistas), é possível que apenas um operador não consiga ser aplicado a todas as imagens. Ou seja, construir operadores com facilidade é um fator sensível para a viabilização desta abordagem.

Nesta seção apresentamos um método para projetar operadores morfológicos de forma automática utilizando técnicas de aprendizado computacional.

O método proposto na tese de mestrado de Nina S. T. Hirata [2] requer que um conjunto de pares de imagens sejam fornecidos para uma etapa inicial de treinamento. Estes pares contém uma imagem **original** e sua **ideal**, ou seja, a mesma imagem porém modificada como desejamos que o método aprenda a reproduzir em outras imagens.

A partir deste conjunto de treinamento um operador é gerado, o qual podemos aplicar a outras imagens.

3.1 Formalização

Assumimos que as imagens originais e ideias são realizações dos conjuntos aleatórios S e I, com distribuição de probabilidade conjunta $P(S, I)$. Supõe-se que esta função seja caracterizada por um processo local $(S \cap Wz, I(z))$, com $S \cap Wz \in P(W_z)$, conjunto potência de W_z, e $I(z) \in \{0, 1\}$. Ou seja, as imagens de exemplo passam a ser vistas como realizações de conjuntos aleatórios localmente definidos pela janela W. Denotaremos este processo por (X, y).

Desta forma, o trabalho de construção de um operador l.d. e i.t. ψ que se aproxime do operador ideal Ψ, passa a ser o de minizar o erro absoluto médio (MAE), dado pela seguinte expressão:

$$MAE(\Psi) = E[|\psi(X) - y|]. \tag{6}$$

Desenvolvendo a expressão acima, chegamos ao critério para decidir o valor de $\psi(X)$ para cada X.

$$\begin{aligned} MAE(\Psi) &= \sum_{(X,y)} |\psi(X) - y| P(X, y) \\ &= \sum_{(X,0)} \psi(X) P(X, 0) + \sum_{(X,1)} |\psi(X) - 1| P(X, 1) \\ &= \sum_{X\,:\,\psi(X)=1} P(X, 0) + \sum_{X\,:\,\psi(X)=0} P(X, 1) \end{aligned} \tag{7}$$

Ou seja, para minimizar o MAE basta que escolhamos de forma adequada os valores de $\psi(X)$ de acordo com estimativas das probabilidades $P(X, 0)$ e $P(X, 1)$ através da observação dos exemplos fornecidos.

A seguir detalhamos as etapas envolvidas na construção de ψ.

3.2 Coleta

Seja $C(X_W) = \{X \cap W + z\colon z \in E\}$ o conjunto de todas as configurações observadas ao se transladar a janela W sobre a imagem X. Seja Y_z o valor 0 ou 1 encontrado na imagem Y na posição z. Construímos uma tabela com três colunas: $C(X_W)$, frequência observada $Y_z = 0$ e frequência $Y_z = 1$.

O resultado desta etapa é uma estimativa $\hat{P}(X, y)$ de $P(X, y)$.

3.3 Decisão

As configurações observadas na etapa anterior possuirão valores relacionados em Y iguais a 0, 1 ou ambos. No caso de tanto 1 como 0 terem sido observados, escolheremos como valor para a função final a com maior número de ocorrências. No caso de alguma configuração não ter sido observada ou de o número de ocorrências empatar, escolheremos o valor que simplifica a próxima etapa: minimização.

Formalmente, se $\hat{P}(X,1) > \hat{P}(X,0)$, então $\psi(X) = 1$, do contrário $\psi(X) = 0$.

3.4 Minimização

Na etapa anterior é usual que nem todos os padrões possíveis para X sejam observados. Logo precisamos completar a definição da função $\psi(X)$. Para tanto utilizamos um minimizador de funções booleanas chamado ISI. Ele não só completa a função como também produz uma representação mais compacta utilizando intervalos maximais.

Um algoritmo bastante conhecido para realizar a minimização de funções booleanas é o algoritmo de QM (Quine-McCluskey), onde através de combinações dois a dois dos mintermos de uma expressão booleana procura-se criar cubos cada vez maiores, eliminando depois os cubos sobressalentes a fim de obter uma cobertura mínima da função.

Porém esta etapa de combinação dois a dois tende a ser computacionalmente ineficiente. Além de que a etapa para identificação dos n-cubos primos (aqueles que não podem ser descartados) é muito custosa computacionalmente.

Por estes motivos, a biblioteca TRIOS [3], que implementa todo o processo descrito nesta seção, utiliza um outro algoritmo denominado ISI. Este algoritmo inicia com o n-cubo, representado na forma do intervalo $[\emptyset, W]$ e a cada iteração remove um ponto do n-cubo equivalente um mintermo negativo. Desta forma quebrando o intervalo inicial em outros N intervalos. Após eliminar todos os mintermos negativos chegamos um conjunto de intervalos maximais que representam a função. Uma descrição mais detalhada do algoritmo pode ser encontrada em [2].

Esta é a última etapa do processo. Podemos agora aplicar o operador a outras imagens.

4 Metodologia

O método proposto é baseado em operadores morfológicos automaticamente gerados, ou seja, construímos um segmentador genérico a partir de alguns exemplos de segmentação (pares de imagens). A seguir detalhamos cada uma das etapas envolvidas.

1. Preparação das imagens de treinamento
2. Construção dos operadores
3. Aplicação dos operadores
4. Consensualização

4.1 Preparação das imagens de treinamento

O primeiro passo consiste na produção dos pares de imagens de treinamento. Estes pares consistem da imagem original binarizada e de sua variante segmentada.

Para cada imagem original geramos n pares de exemplo, sendo n o número de tipos de regiões que desejamos segmentar. No caso deste trabalho nos limitamos a dois: textos de parágrafos e título.

A variante segmentada consiste da imagem original com a região de interesse apagada (em braco). A tabela 1 é um exemplo com uma imagem original, binarizada e suas variantes.

Tabela 1: Exemplo de preparação de imagem para treinamento do operador

Original	Preto e branco	Exemplo de parágrafo	Exemplo de título
		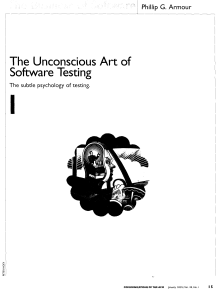	

O processo de binarização foi melhor detalhado no apêndice 8.1.

4.2 Construção dos operadores

O algoritmo gerador de operadores morfológicos recebe como entrada um conjunto de pares de imagens de exemplo do passo anterior. Treinamos um operador para cada tipo de região utilizando a biblioteca TRIOS [3]. Os parâmetros para o treinamento foram ajustados experimentalmente como apresentado na seção 5.

4.3 Aplicação dos operadores

Construídos os operadores para cada tipo de região, aplicamos todos os operadores às imagens que desejamos segmentar obtendo um resultado para cada operador. Sendo n operadores e m

imagens, obtemos nm resultados. A tabela 2 demonstra a aplicação dos operadores de parágrafo e título a uma imagem.

Tabela 2: Exemplo de preparação de imagem para treinamento do operador

Original	Operador de parágrafo	Operador de título
	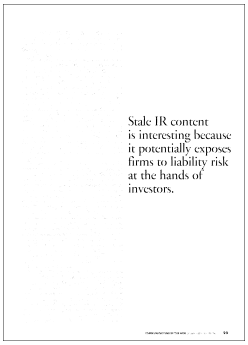	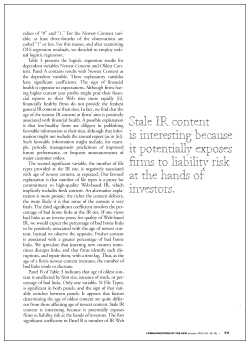

4.4 Consensualização

A aplicação de operadores diferentes à mesma imagem pode gerar resultados incoerentes. Pixeis classificados como pertencentes a mais de uma região fazem com que a união dos resultados seja impossível sem nenhum tipo de processamento. Para concluirmos a segmentação é necessário chegar a um consenso sobre qual operador possui a maior probabilidade de estar certo a cada pixel de classificação conflitante.

Partindo da observação de que pixel pertencente a uma certa região costuma estar cercados por pixeis da mesma região, aplicamos um processo de escolha por maior contagem de pixeis na vizinhança. Ou seja, se houver um conflito de classificação de um pixel entre texto ou título, conta-se quantos pixeis na vizinhança pertencem a uma dada região e a que obtiver maior contagem ganha.

5 Experimentos

Realizamos experimentos variando diversos parâmetros em diferentes etapas da segmentação. Apesar de usarmos uma técnica de aprendizado computacional para automatizar parte do processo, identificar quais parâmetros produzem o melhor resultado a um custo desejável (tempo de processamento e poder computacional) é uma tarefa ainda experimental.

A qualidade da solução e o tempo levado para processá-lo foram medidos a fim de identificar o lucus optimus, ou seja, a combinação que produz um bom resultado com um tempo de processamento razoável.

Os parâmetros escolhidos para análise foram:

- Mistura de publicações no conjunto de treinamento.
- Quantidade de imagens no conjunto de treinamento.
- Tipos de regiões.
- Formatos de janelas.
- Tamanhos de janelas para consensualização.

A seguir detalhamos os valores dos parâmetros e os motivos de sua escolha.

5.1 Base de dados

As imagens utilizadas nos experimentos foram obtidas de um banco de dados construído pelos pesquisadores do PRImA ao longo de anos [4]. Ele inclui um conjunto de documentos que busca simular um cenário realístico de aplicação, com layouts complexos e diferentes tipos de fontes e formatos de regiões. Isto é importante para avaliar a aplicabilidade do método em situações práticas, onde um controle sobre o formato do conteúdo seria indesejável ou inviável.

No artigo [4], os autores apresentam um conjunto de dados com páginas de revistas, artigos científicos diversos, documentos modernos e não apenas históricos.

O conjunto de dados contém não só imagens mas também arquivos XML [5] com metadados como informações bibliográficas (título, autor, publicação), informações das imagens (resolução, bit depth, modelo do scanner), características do layout (número de colunas, variedade de tamanhos de fontes) e informações administrativas (direitos autorais).

Os documentos são digitalizados com um cartão escuro por trás para minimizar a exposição da contra página. Posteriormente um algoritmo analisa possíveis falhas, como rotação do documento, marcando-os para redigitalização. Uma correção automática não é utilizada, pois isto pode comprometer a qualidade da imagem.

Uma vez que a imagem foi aceita no banco de dados, inicia-se um processo manual de marcação do grownd-truth. Este trabalho deve ser realizado da forma mais precisa possível, pois é a base para determinar a corretude dos algoritmos segmentadores. Por se tratar de uma etapa muito custosa, uma ferramenta semi-automática chamada Aletheia [6] é utilizada para agilizar o processo. Esta ferramenta permite a uma pessoa desenhar uma região poligonal em torno de uma região de interesse. Em seguida esta região é automaticamente ajustada pelo software, como se a pessoa estivesse colocando um elástico que aperta a região.

5.2 Mistura de publicações no conjunto de treinamento

Diferentes publicações trabalham com fontes e grafismos próprios. A diferença fica evidente ao comparar um jornal antigo com uma revista sobre tecnologia. Incluir imagens de publicações

diversas no mesmo conjunto de imagens de treinamento pode produzir operadores menos precisos. Mesmo entre publicações do mesmo período, podemos ter diferentes tamanhos de fontes e famílias de tipos. Este experimento tem por objetivo analisar o impacto na qualidade por tentar criar operadores mais genéricos.

Testamos os seguintes conjuntos de imagens de treinamento:

- Comunications of the ACM: 263, 674, 677, 680, 683, 685, 686, 689, 692, 695, 802 e 803. Este conjunto é chamado de CACM neste texto.
- TIME Magazine: 232, 720, 721, 723, 782, 783, 784, 785 e 786. Este conjunto é chamado de TIME neste texto.

5.3 Tipos de regiões

Os gabaritos do conjunto de dados utilizados nestes experimentos rotulam com detalhes cada região das imagens:

1. Text
   (a) Header
   (b) Headings (título)
   (c) Capital (letras maiores)
   (d) Drop Capital
   (e) Credit
   (f) Paragraph (parágrafo)
   (g) Floating
   (h) Page number
   (i) Footer
2. Graphic
3. Math
4. Chart
5. Image
6. Noise
7. Separator
8. Table

Nos experimentos realizados nos limitamos a Text Heading e Text Paragraph por limitações de custo e tempo.

5.4 Quantidade de imagens de treinamento

A quantidade de imagens no conjunto de treinamento pode afetar a variedade e quantidade de padrões amostrados, influenciando diretamente a qualidade da solução. A sensibilidade a este fator pode depender do tipo de região a ser segmentada, caso a quantidade de amostras por imagem varie por região. O tempo para se treinar o operador também é impactado, pois deve-se coletar mais amostras.

Treinamos operadores utilizando cinco tamanhos de conjuntos (de uma a cinco imagens).

5.5 Formatos de janelas

Variando o tamanho da janela procuramos capturar padrões característicos de cada tipo de região. O tamanho da janela impacta o tempo de processamento da etapa mais custosa que é a minimização, logo descobrir um tamanho de janela com um bom custo benefício é essencial para aplicações práticas. Sabemos que nem sempre janelas maiores produzem resultados melhores, portanto este experimento procura descobrir o melhor.

Utilizamos janelas densas e esparsas, ou seja, janelas com todos os pontos preenchidos ou apenas alguns. Os tamanhos variam de 3x3 a 7x7 para densas e de 3x3 a 11x11 para as esparsas.

5.6 Tamanho da janela de consensualização

Experimentamos janelas variando de 3x3 a 15x15. Procuramos entender até quando a hipótese de que pixeis de uma determinada região não ocorrem isoladamente é verdadeira.

5.7 Aplicação

Construímos 200 operadores e os aplicamos aos nossos conjuntos de imagens de teste, cada um contendo imagens não envolvidas no treinamento dos operadores. Salvamos todas as imagens produzidas, totalizando 6.8 GB em resultados.

Após aplicarmos todos os operadores, executamos o processo de consensualização para finalmente classificarmos os pixeis como pertencentes a um parágrafo, título ou desconhecido.

5.8 Avaliação da segmentação

Os dois principais métodos utilizados para avaliar a qualidade das soluções para este problema são a comparação da classificação dos pixeis individualmente ou a classificação de regiões, como sugerido no artigo [7]. Optamos pela comparação entre pixeis, pois nosso método produz como resultado a classificação de pixeis e não a delimitação de regiões. Seria necessário agrupar os pixeis em regiões para que pudéssemos realizar outros tipo de avaliação, o que foge ao escopo deste trabalho.

Uma vantagem na comparação entre pixeis e não regiões é o fato de que evitamos restrições arbitrárias na forma das regiões, porém utilizamos muito mais espaço do que o formato de regiões delimitadas por polígonos.

6 Resultados

O processo de segmentação foi avaliado após a aplicação do operador morfológico. Para cada imagem processada contamos a quantidade de classificações em cada uma das categorias de erro ou acerto da tabela 3. A partir da contagem destas classes calculamos quatro métricas diferentes tabeladas em 4. Apenas contamos quando o pixel na imagem original é ligado.

Tabela 3: Tabela com classes de resultados

		Classificado como	
		positivo	negativo
Gabaritado como	positivo	Verdadeiro positivo (tp). Pixel apagado corretamente.	Falso negativo (fn). Pixel deveria ter sido apagado.
	negativo	Falso positivo (fp). Pixel não deveria ter sido apagado.	Verdadeiro negativo (tn). Pixel mantido ligado corretamente.

Tabela 4: Métricas para avaliação de desempenho dos operadores

Métrica	Fórmula	Pior desempenho	Valor ótimo
Precision (Precisão)	$\frac{tp}{tp+fp}$	0	1
Recall (Sensibilidade)	$\frac{tp}{tp+fn}$	0	1
F-measure	$2\frac{PrecisionRecall}{Precision+Recall}$	0	1
MCC	$\frac{tptn-fpfn}{\sqrt{(tp+fp)(tp+fn)(tn+fp)(tn+fn)}}$	-1	1

- Precision (Precisão): quantidade de pixeis corretamente classificados como pertencentes a uma região dividido pelo total de pixeis classificados.
- Recall (Sensibilidade): quantidade de pixeis corretamente classificados sobre quantidade de todos os pixeis que deveria ter sido classificados.
- F-measure: média harmônica de Precision e Recall.
- MCC (Coeficiente de correlação de Mathew): Métrica bastante utilizada na avaliação de classificadores binários. Leva em consideração verdadeiros e falso positivos e negativos. O valor 0 indica que o classificador é equivalente a um classificador aleatório. Funciona bem com classes de tamanhos muito diferentes.

A métrica utilizada nas referências teóricas sobre operadores morfológicos automaticamente gerados é o MAE (sigla em inglês para Erro Absoluto Médio), cuja fórmula pode ser escrita como $\frac{fp+fn}{N}$, sendo N o número total de pixeis na imagem. Porém esta métrica não é muito elucidadora para avaliar segmentação de páginas. Se, por exemplo, um dado operador ideal afetar 5% dos pixeis de uma imagem e o operador gerado afetar 5% dos pixeis da imagem não pertencentes aos 5% do ideal, o MAE seria de 5%. Ou seja, o operador errou todos os pixeis que ele deveria ter modificado e ainda modificou outros indevidamente. Ela não distingue entre diferentes tipos de erro como rotulação parcial de regiões e rotulação indevida de regiões. Já o F-measure resultaria em 0 e o MCC (Coeficiente de Correlação de Matthew) poderia inclusive apresentar um valor negativo.

6.1 Valores observados

As tabelas 5, 6, 7 e 8 contém os valores de Precision, Recall, F-measure e MCC para a classificação de parágrafos do conjunto de teste CACM. As tabelas 9, 10, 11 e 12 contém os valores para classificação de parágrafos do conjunto TIME. As tabelas 13, 14, 15, 16, 17, 18, 19 e 20 contém os valores para a classificação de títulos. Cada tabela possui um gráfico correspondente com as janelas na horizontal, o valor da métrica na vertical. Cada cor de barra está relacionada a um tamanho de conjunto de treinamento.

Também apresentamos o tempo, em escala linear (figuras 2 e 3) e logarítmica (figuras 4 e 5) para a construção dos operadores de parágrafo e título.

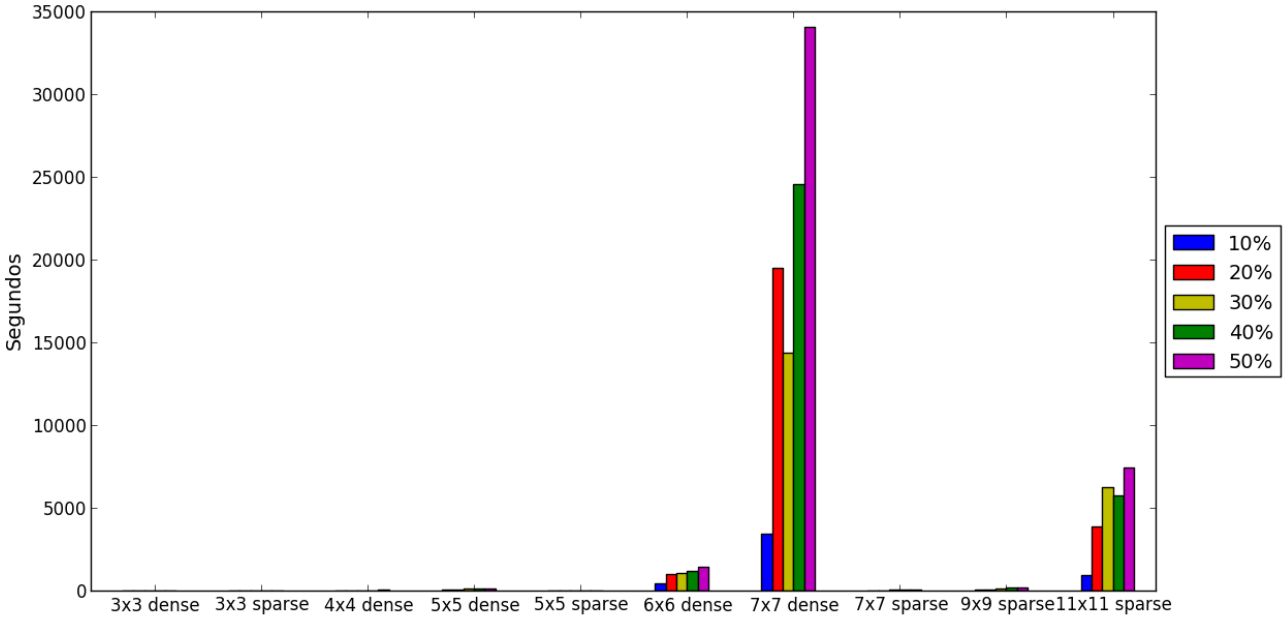

Figura 2: Tempo para treinamento dos operadores de parágrafo

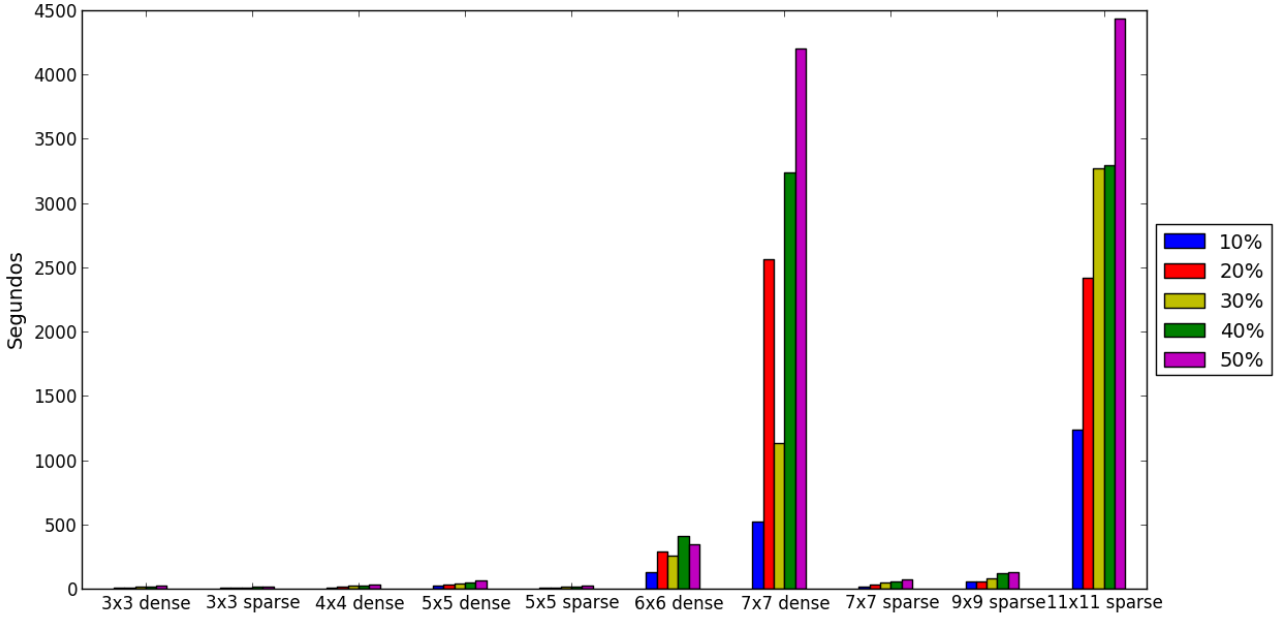

Figura 3: Tempo para treinamento dos operadores de título

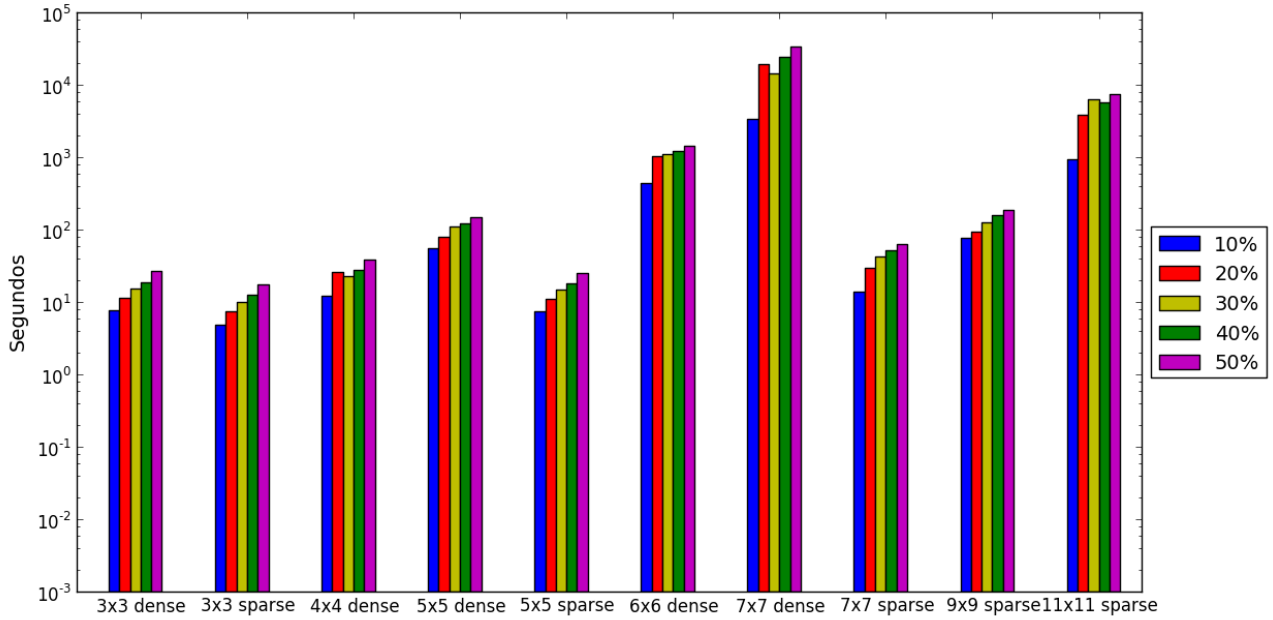

Figura 4: Tempo para treinamento dos operadores de parágrafo em escala logarítmica

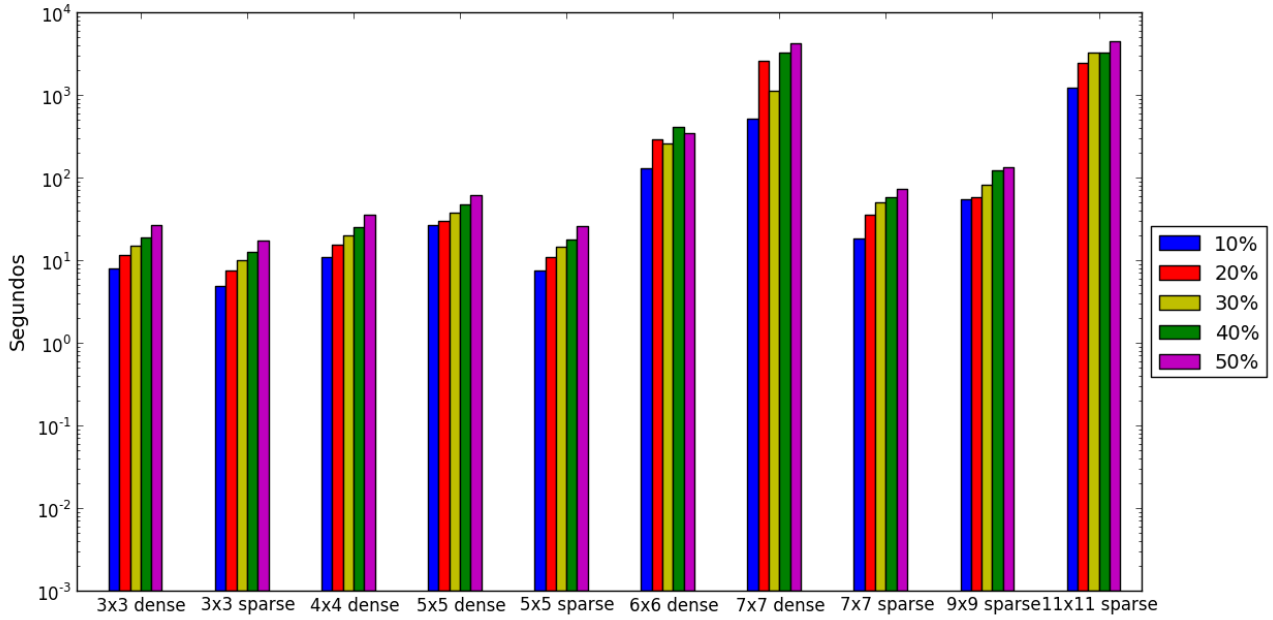

Figura 5: Tempo para treinamento dos operadores de título em escala logarítmica

Tabela 5: Média da precisão na classificação de parágrafos do conjunto de dados CACM

	janelas									
	densa					esparsa				
	3x3	4x4	5x5	6x6	7x7	3x3	5x5	7x7	9x9	11x11
10%	0.6955	0.8419	0.8850	0.9166	0.9396	0.6953	0.8718	0.9038	0.9527	0.9230
20%	0.8378	0.8557	0.8845	0.8926	0.9076	0.8376	0.8744	0.8859	0.9296	0.9029
30%	0.8383	0.8690	0.8911	0.8979	0.9141	0.8376	0.8751	0.8921	0.9345	0.9047
40%	0.8428	0.8635	0.8885	0.8943	0.9117	0.8376	0.8651	0.8820	0.9291	0.9025
50%	0.8418	0.8465	0.8826	0.8918	0.9125	0.8376	0.8601	0.8831	0.9289	0.9044

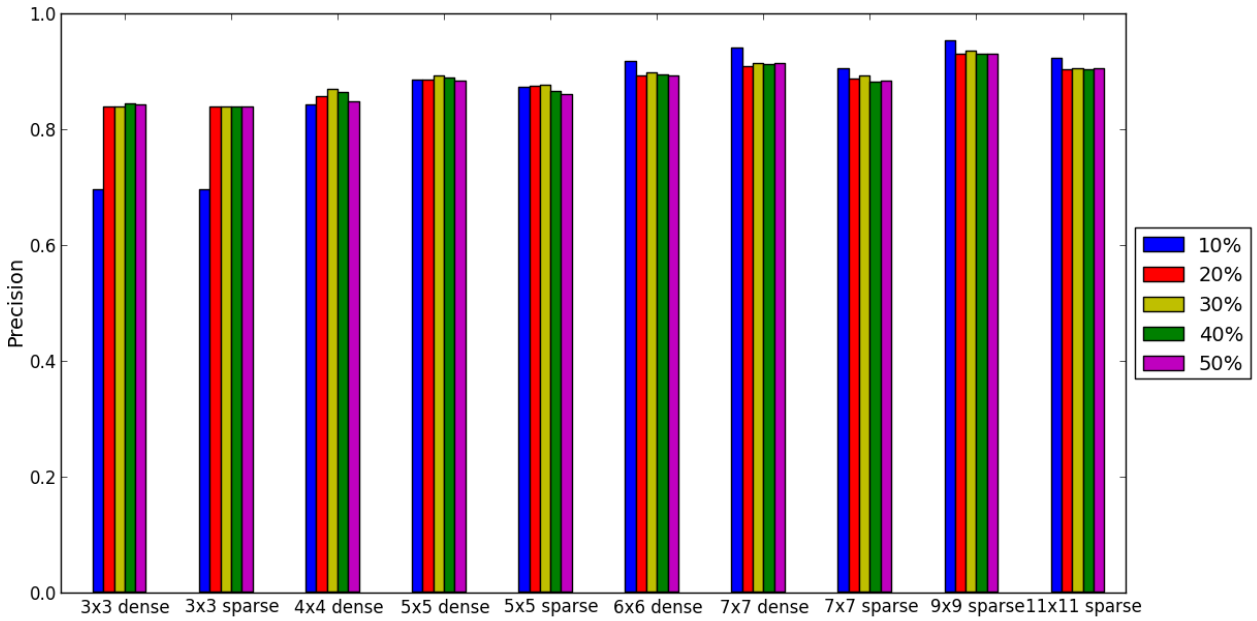

Figura 6: CACM: Classificação de parágrafos

Tabela 6: Média recall na classificação de parágrafos do conjunto de dados CACM

	janelas									
	densa					esparsa				
	3x3	4x4	5x5	6x6	7x7	3x3	5x5	7x7	9x9	11x11
10%	0.9999	0.9537	0.9817	0.9736	0.9718	1.0000	0.9906	0.9937	0.9863	0.9866
20%	0.7796	0.9461	0.9778	0.9686	0.9677	0.7781	0.9894	0.9944	0.9823	0.9829
30%	0.7795	0.9316	0.9740	0.9683	0.9668	0.7781	0.9886	0.9928	0.9829	0.9848
40%	0.7789	0.9433	0.9739	0.9643	0.9641	0.7781	0.9886	0.9928	0.9810	0.9832
50%	0.7796	0.9591	0.9879	0.9802	0.9781	0.7781	0.9939	0.9953	0.9884	0.9896

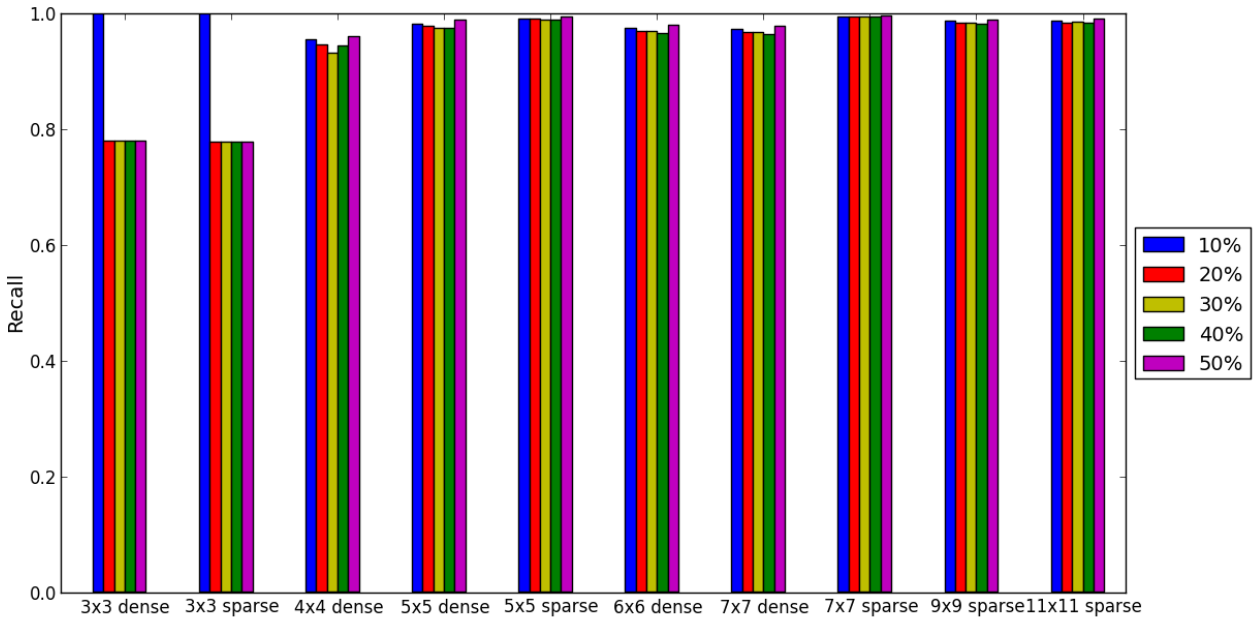

Figura 7: CACM: Classificação de parágrafos

Tabela 7: Média F1 na classificação de parágrafos do conjunto de dados CACM

	janelas									
	densa					esparsa				
	3x3	4x4	5x5	6x6	7x7	3x3	5x5	7x7	9x9	11x11
10%	0.8088	0.8932	0.9304	0.9440	0.9553	0.8087	0.9268	0.9462	0.9691	0.9534
20%	0.8067	0.8979	0.9284	0.9287	0.9365	0.8058	0.9278	0.9366	0.9550	0.9409
30%	0.8068	0.8987	0.9303	0.9315	0.9396	0.8058	0.9279	0.9394	0.9580	0.9428
40%	0.8087	0.9010	0.9288	0.9277	0.9370	0.8058	0.9221	0.9337	0.9542	0.9409
50%	0.8086	0.8984	0.9319	0.9336	0.9440	0.8058	0.9215	0.9354	0.9576	0.9448

Tabela 8: Média MCC na classificação de parágrafos do conjunto de dados CACM

	janelas									
	densa					esparsa				
	3x3	4x4	5x5	6x6	7x7	3x3	5x5	7x7	9x9	11x11
10%	0.0212	0.5591	0.7194	0.7746	0.8199	0.0006	0.6999	0.7775	0.8669	0.8100
20%	0.3717	0.5825	0.7123	0.7134	0.7460	0.3691	0.7025	0.7312	0.8123	0.7560
30%	0.3726	0.5940	0.7205	0.7276	0.7621	0.3691	0.7022	0.7434	0.8261	0.7671
40%	0.3815	0.5950	0.7105	0.7087	0.7497	0.3691	0.6803	0.7187	0.8095	0.7568
50%	0.3795	0.5740	0.7246	0.7302	0.7767	0.3691	0.6810	0.7259	0.8235	0.7743

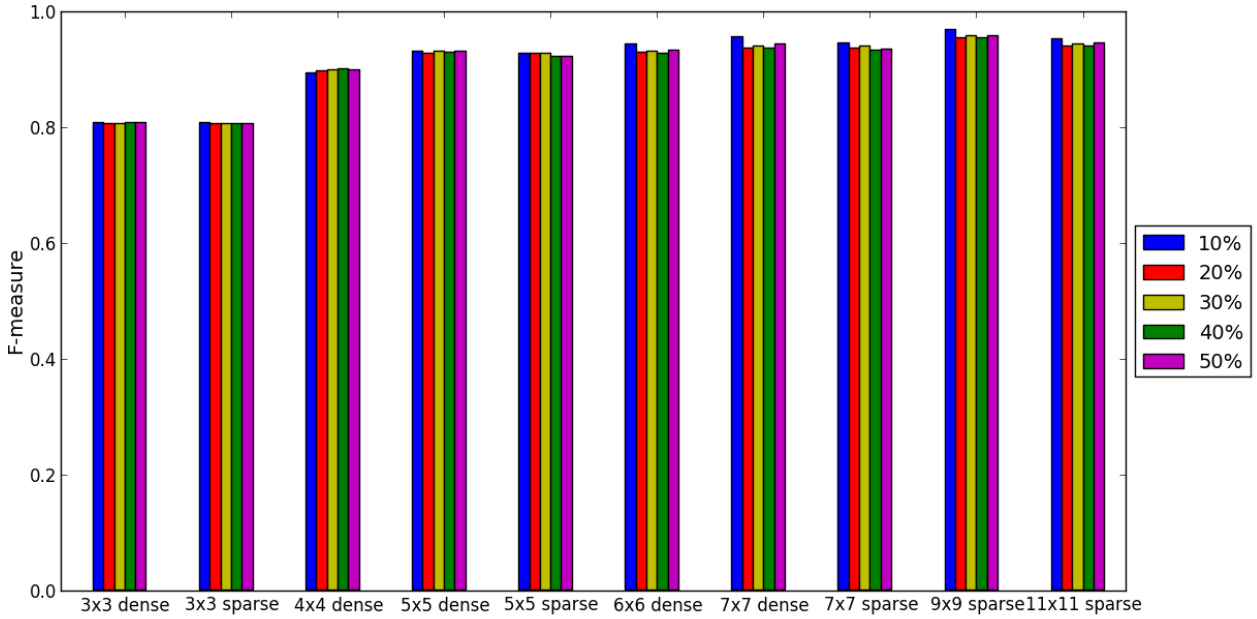

Figura 8: CACM: Classificação de parágrafos

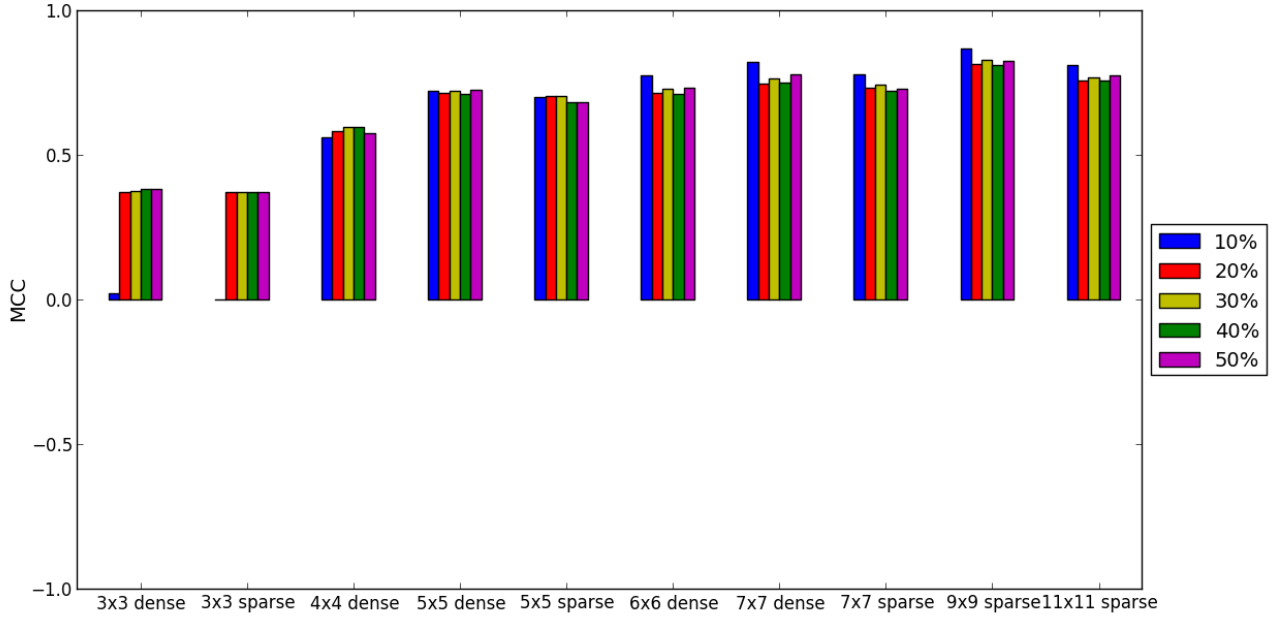

Figura 9: CACM: Classificação de parágrafos

Tabela 9: Média da precisão na classificação de parágrafos do conjunto de dados TIME

	janelas									
	densa					esparsa				
	3x3	4x4	5x5	6x6	7x7	3x3	5x5	7x7	9x9	11x11
10%	0.7725	0.8186	0.8662	0.8856	0.9093	0.7226	0.8536	0.8119	0.8968	0.8095
30%	0.7729	0.8123	0.8699	0.9007	0.9177	0.7226	0.8440	0.8188	0.9032	0.8210
40%	0.7466	0.7997	0.8655	0.9008	0.9211	0.7077	0.7858	0.8155	0.9044	0.8271
50%	0.7493	0.8139	0.8775	0.9087	0.9304	0.7226	0.8364	0.8221	0.9094	0.8272

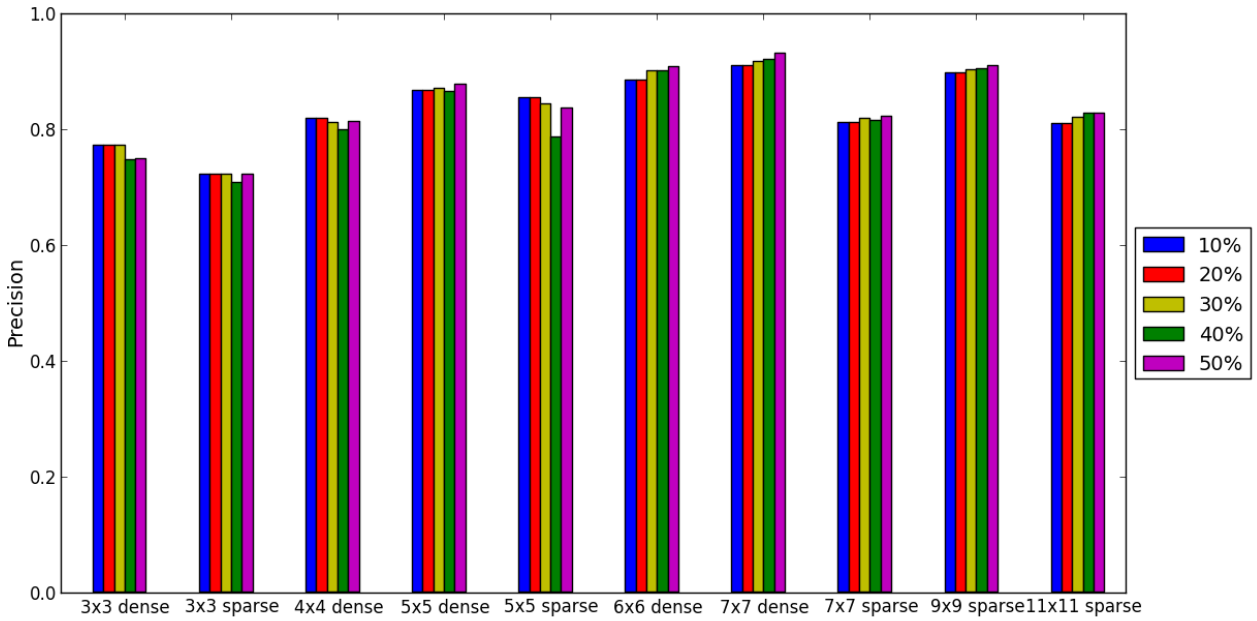

Figura 10: TIME: Classificação de parágrafos

Tabela 10: Média recall na classificação de parágrafos do conjunto de dados TIME

	janelas									
	densa					esparsa				
	3x3	4x4	5x5	6x6	7x7	3x3	5x5	7x7	9x9	11x11
10%	0.6025	0.7503	0.7864	0.7966	0.8039	0.7645	0.6514	0.9461	0.8761	0.9172
30%	0.6011	0.7712	0.7990	0.8170	0.8286	0.7645	0.6825	0.9489	0.8939	0.9263
40%	0.7304	0.8761	0.9166	0.9281	0.9269	0.8087	0.9228	0.9872	0.9640	0.9734
50%	0.7212	0.8436	0.8982	0.9177	0.9251	0.7645	0.7446	0.9790	0.9595	0.9728

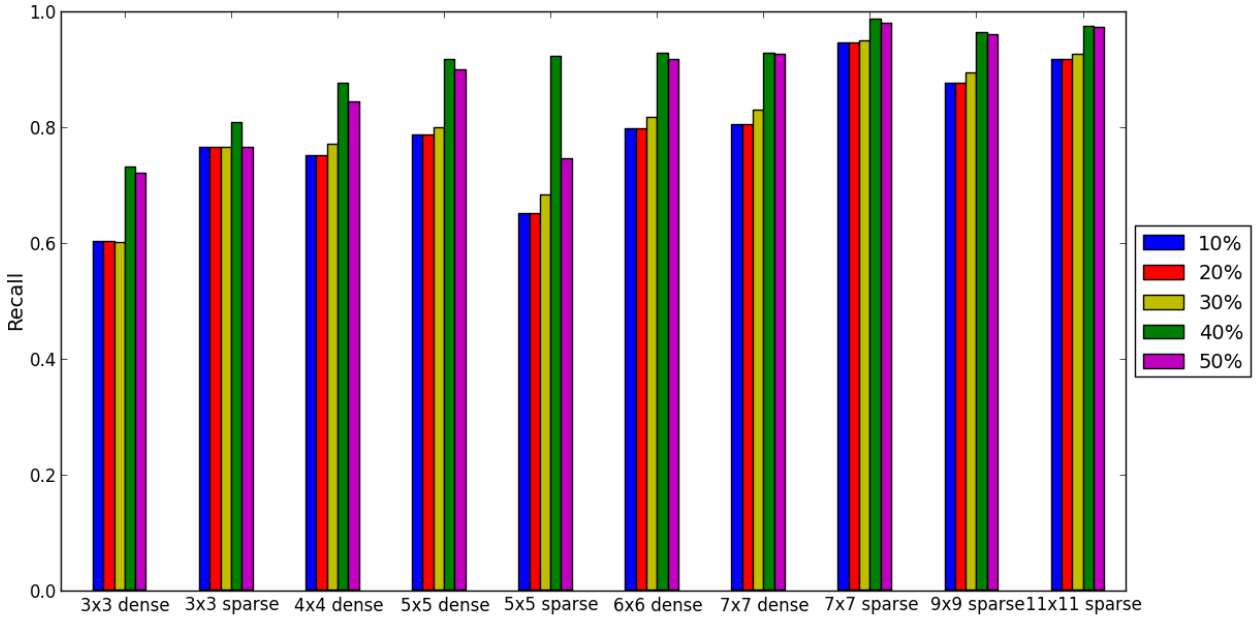

Figura 11: TIME: Classificação de parágrafos

Tabela 11: Média F1 na classificação de parágrafos do conjunto de dados TIME

	janelas									
	densa					esparsa				
	3x3	4x4	5x5	6x6	7x7	3x3	5x5	7x7	9x9	11x11
10%	0.6757	0.7819	0.8230	0.8374	0.8519	0.7418	0.7373	0.8733	0.8857	0.8594
30%	0.6750	0.7902	0.8315	0.8553	0.8694	0.7418	0.7532	0.8785	0.8980	0.8699
40%	0.7372	0.8353	0.8897	0.9138	0.9235	0.7536	0.8479	0.8927	0.9330	0.8940
50%	0.7338	0.8276	0.8868	0.9123	0.9270	0.7418	0.7869	0.8932	0.9335	0.8937

Tabela 12: Média MCC na classificação de parágrafos do conjunto de dados TIME

	janelas									
	densa					esparsa				
	3x3	4x4	5x5	6x6	7x7	3x3	5x5	7x7	9x9	11x11
10%	0.5438	0.6720	0.7350	0.7575	0.7817	0.6004	0.6376	0.8007	0.8224	0.7784
30%	0.5431	0.6801	0.7467	0.7844	0.8059	0.6004	0.6507	0.8091	0.8407	0.7958
40%	0.6010	0.7393	0.8253	0.8642	0.8799	0.6137	0.7601	0.8352	0.8939	0.8362
50%	0.5977	0.7310	0.8227	0.8629	0.8863	0.6004	0.6854	0.8350	0.8947	0.8363

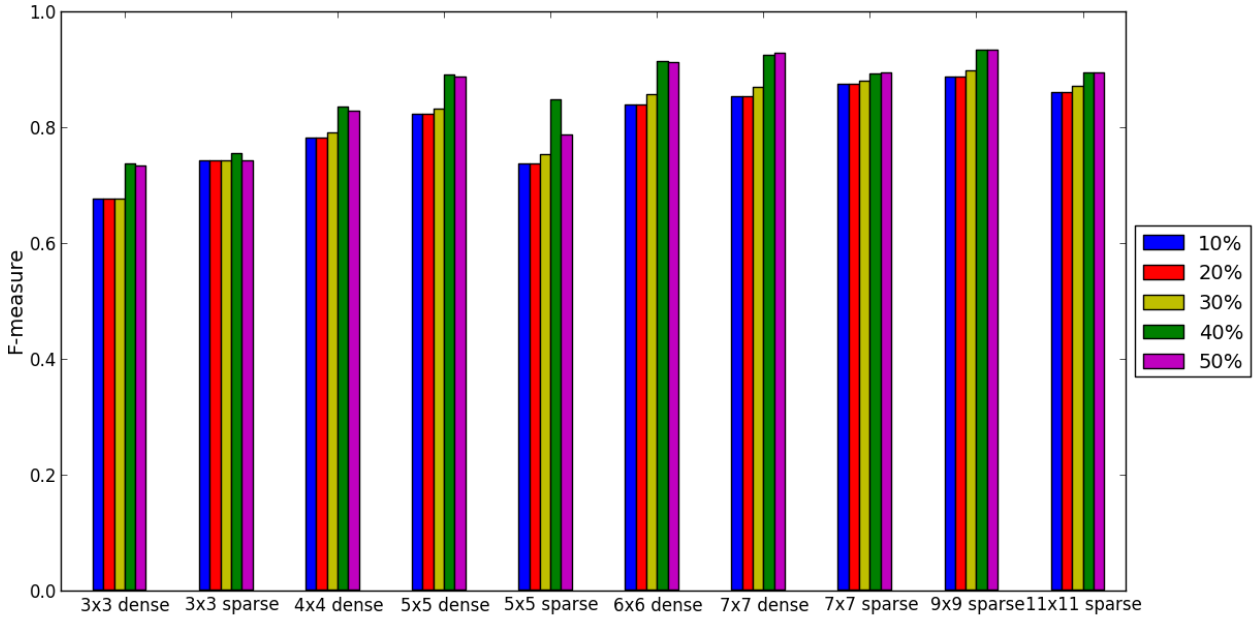

Figura 12: TIME: Classificação de parágrafos

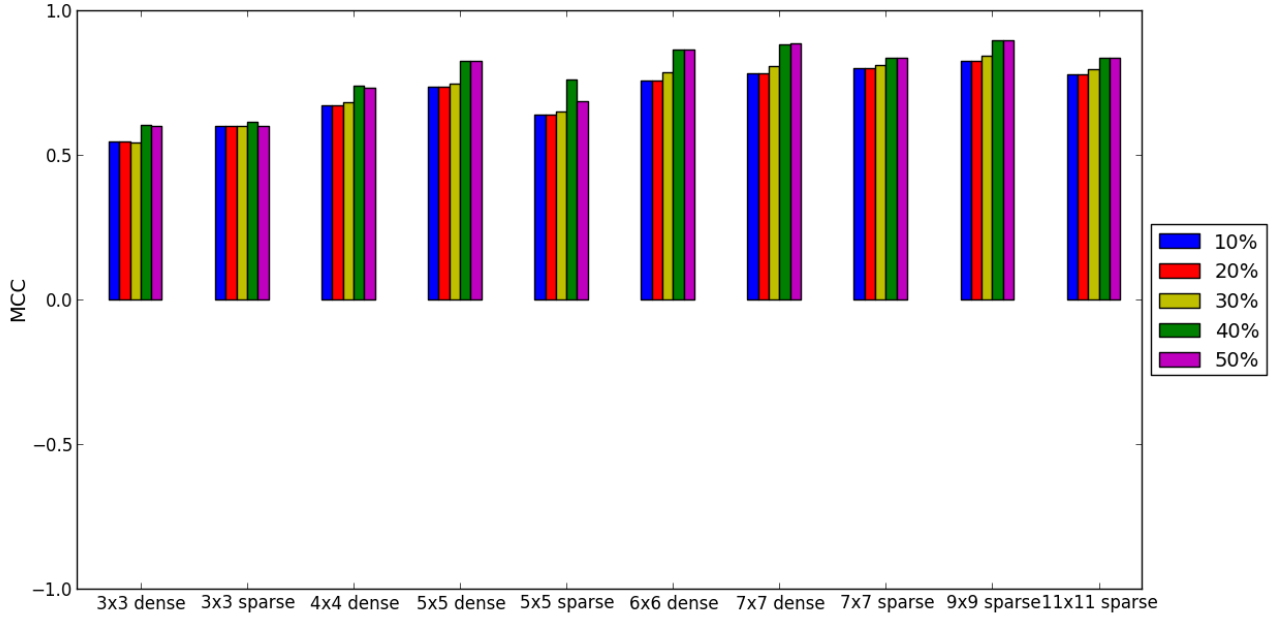

Figura 13: TIME: Classificação de parágrafos

Tabela 13: Média da precisão na classificação de títulos do conjunto de dados CACM

	janelas									
	densa					esparsa				
	3x3	4x4	5x5	6x6	7x7	3x3	5x5	7x7	9x9	11x11
10%	0.0000	0.2115	0.2198	0.2301	0.2335	0.0467	0.2413	0.0910	0.2802	0.1275
20%	0.0000	0.1650	0.1894	0.2171	0.2609	0.0467	0.2485	0.0878	0.2943	0.1676
30%	0.0000	0.1352	0.1115	0.2115	0.2642	0.0467	0.2000	0.0725	0.3060	0.1495
40%	0.0000	0.1518	0.1381	0.2146	0.2637	0.0467	0.2000	0.1006	0.2945	0.1653
50%	0.0000	0.1864	0.1848	0.2334	0.2842	0.0467	0.0000	0.1069	0.3256	0.1771

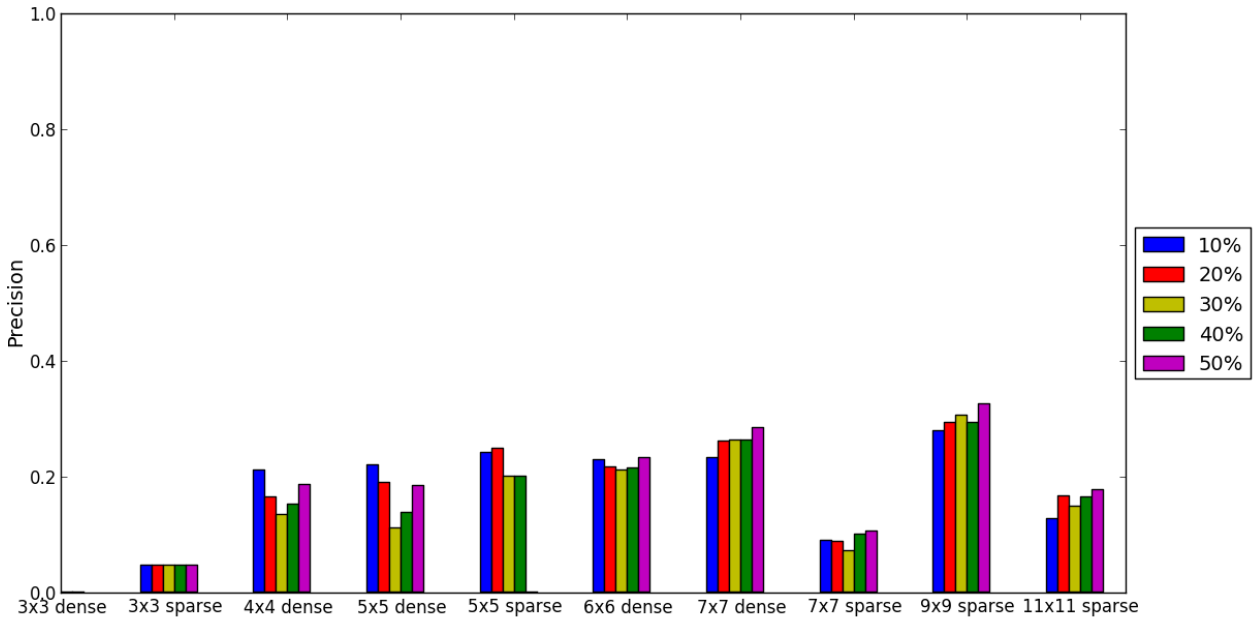

Figura 14: CACM: Classificação de títulos

Tabela 14: Média recall na classificação de títulos do conjunto de dados CACM

	janelas									
	densa					esparsa				
	3x3	4x4	5x5	6x6	7x7	3x3	5x5	7x7	9x9	11x11
10%	0.0000	0.0083	0.0667	0.1420	0.2059	0.1731	0.0130	0.2912	0.2506	0.3712
20%	0.0000	0.0014	0.0382	0.1209	0.2411	0.1731	0.0028	0.2550	0.2931	0.4557
30%	0.0000	0.0003	0.0049	0.0539	0.1683	0.1731	0.0000	0.1883	0.2081	0.3980
40%	0.0000	0.0002	0.0167	0.1091	0.2598	0.1731	0.0000	0.2777	0.2925	0.4640
50%	0.0000	0.0002	0.0269	0.1113	0.2709	0.1731	0.0000	0.2866	0.3531	0.4885

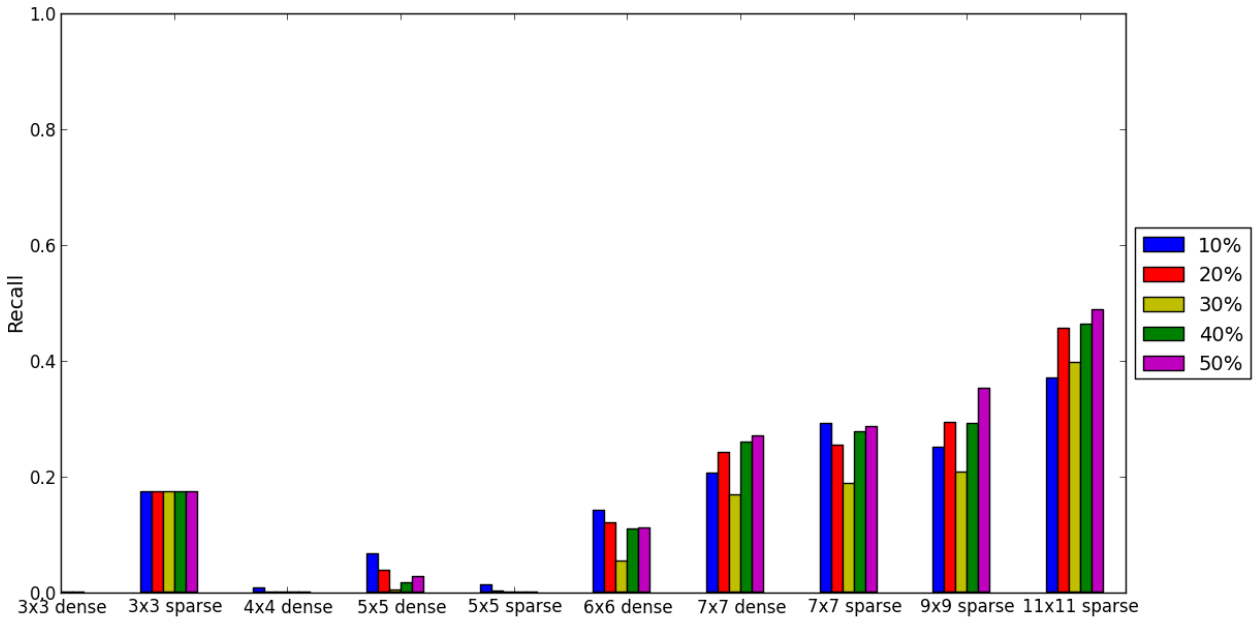

Figura 15: CACM: Classificação de títulos

Tabela 15: Média F1 na classificação de títulos do conjunto de dados CACM

	janelas									
	densa					esparsa				
	3x3	4x4	5x5	6x6	7x7	3x3	5x5	7x7	9x9	11x11
10%	0.0000	0.0152	0.0869	0.1428	0.1766	0.0601	0.0234	0.1119	0.2094	0.1510
20%	0.0000	0.0028	0.0560	0.1311	0.2161	0.0601	0.0054	0.1074	0.2677	0.2116
30%	0.0000	0.0005	0.0088	0.0742	0.1799	0.0601	0.0000	0.0838	0.2308	0.1858
40%	0.0000	0.0004	0.0265	0.1252	0.2319	0.0601	0.0000	0.1234	0.2731	0.2125
50%	0.0000	0.0004	0.0429	0.1331	0.2481	0.0601	0.0000	0.1302	0.3169	0.2259

Tabela 16: Média MCC na classificação de títulos do conjunto de dados CACM

	janelas									
	densa					esparsa				
	3x3	4x4	5x5	6x6	7x7	3x3	5x5	7x7	9x9	11x11
10%	0.0000	0.0243	0.0739	0.1184	0.1484	-0.0879	0.0357	0.0239	0.1958	0.0964
20%	0.0000	0.0078	0.0508	0.1065	0.1849	-0.0879	0.0176	0.0117	0.2342	0.1640
30%	0.0000	0.0020	0.0058	0.0676	0.1551	-0.0879	0.0006	-0.0159	0.2023	0.1264
40%	0.0000	0.0024	0.0203	0.1003	0.1975	-0.0879	0.0008	0.0319	0.2372	0.1637
50%	0.0000	0.0033	0.0416	0.1115	0.2162	-0.0879	0.0000	0.0435	0.2838	0.1851

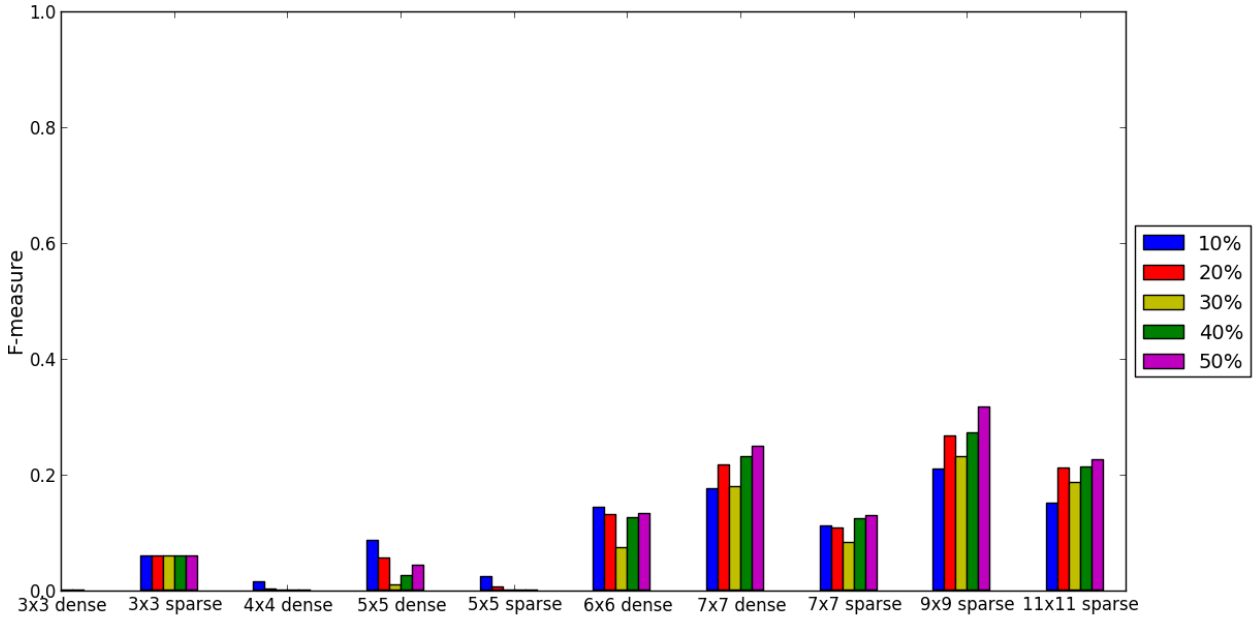

Figura 16: CACM: Classificação de títulos

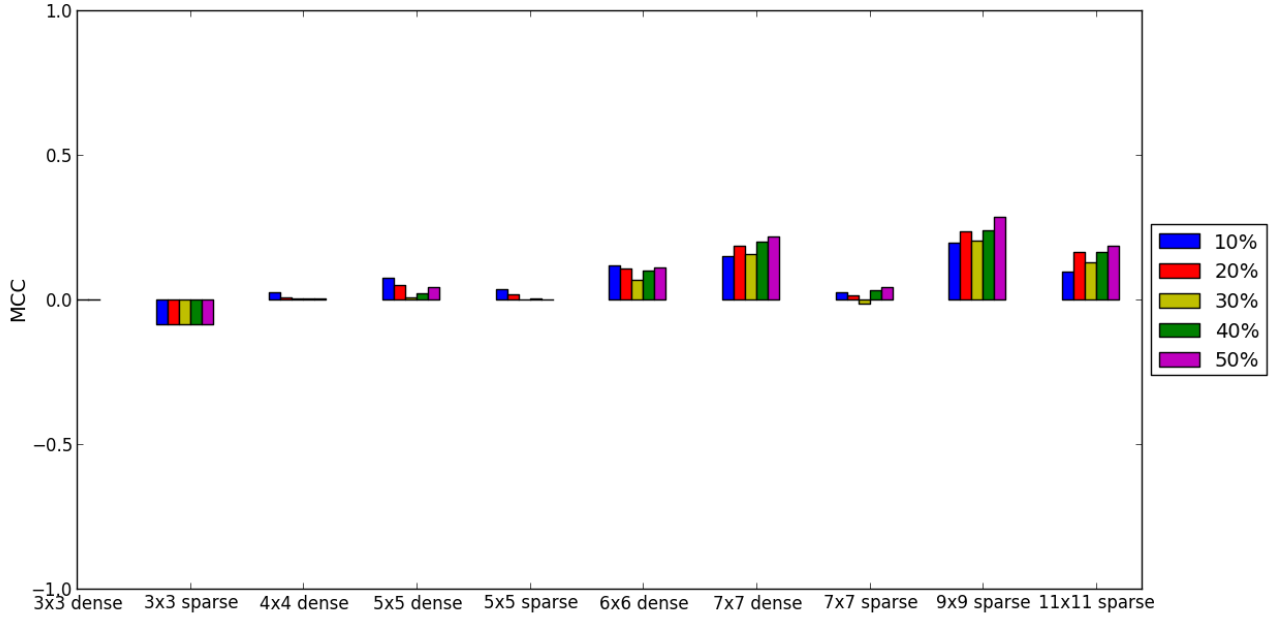

Figura 17: CACM: Classificação de títulos

Tabela 17: Média da precisão na classificação de títulos do conjunto de dados TIME

	janelas									
	densa					esparsa				
	3x3	4x4	5x5	6x6	7x7	3x3	5x5	7x7	9x9	11x11
10%	0.0000	0.0000	0.0020	0.0571	0.0776	0.0189	0.0000	0.0232	0.0510	0.0277
30%	0.0000	0.0000	0.0018	0.0063	0.0137	0.0189	0.0000	0.0227	0.0151	0.0217
40%	0.0000	0.0000	0.0081	0.0203	0.0447	0.0189	0.0000	0.0271	0.0600	0.0297
50%	0.0000	0.0147	0.0122	0.0495	0.0721	0.0189	0.0000	0.0274	0.1172	0.0341

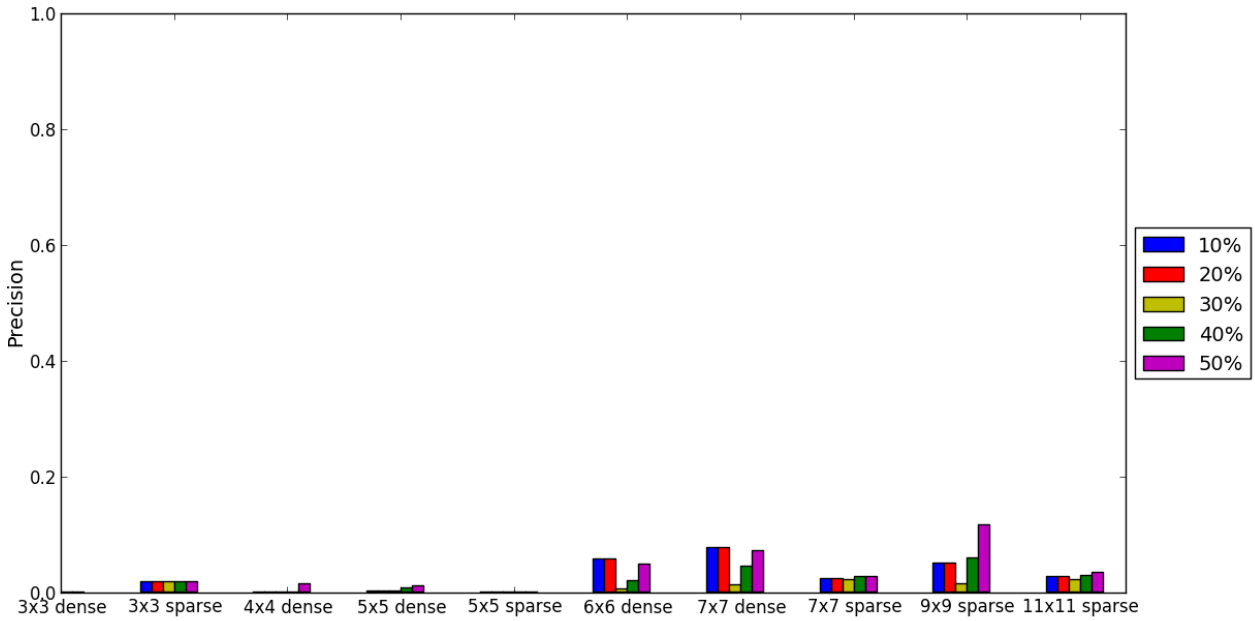

Figura 18: TIME: Classificação de títulos

Tabela 18: Média recall na classificação de títulos do conjunto de dados TIME

	janelas									
	densa					esparsa				
	3x3	4x4	5x5	6x6	7x7	3x3	5x5	7x7	9x9	11x11
10%	0.0000	0.0000	0.0007	0.0610	0.1410	0.1786	0.0000	0.1600	0.0451	0.2089
30%	0.0000	0.0000	0.0004	0.0053	0.0166	0.1786	0.0000	0.1558	0.0108	0.1598
40%	0.0000	0.0000	0.0001	0.0046	0.0210	0.1786	0.0000	0.1626	0.0138	0.1821
50%	0.0000	0.0000	0.0003	0.0056	0.0256	0.1786	0.0000	0.1607	0.0111	0.1943

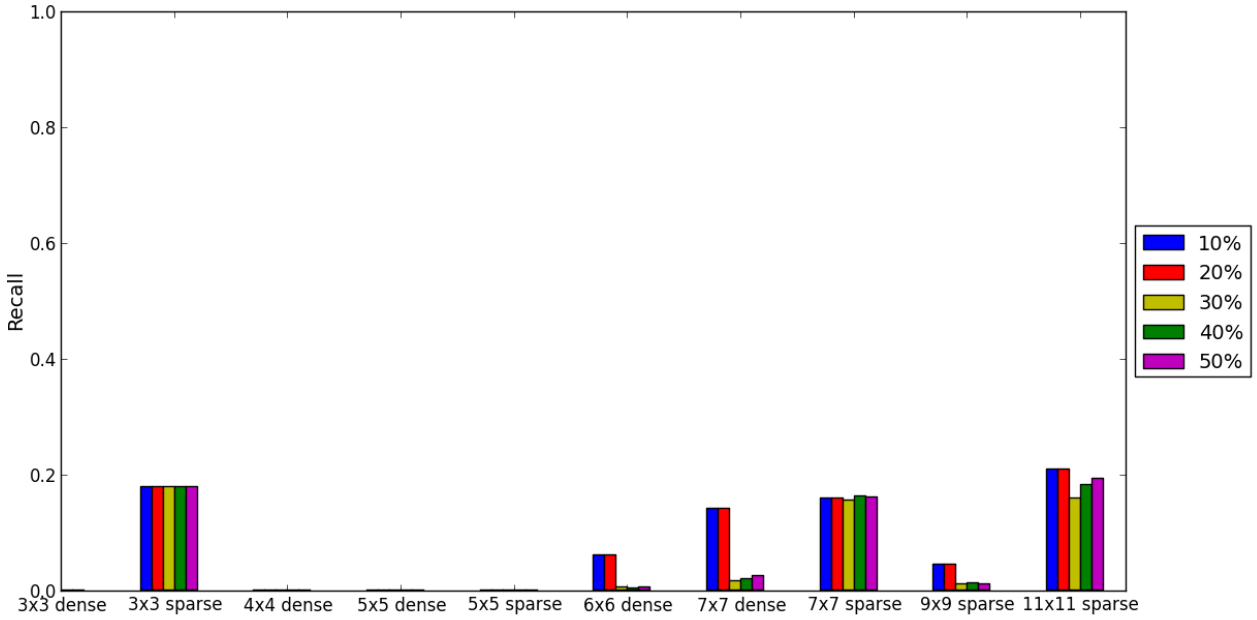

Figura 19: TIME: Classificação de títulos

Tabela 19: Média F1 na classificação de títulos do conjunto de dados TIME

	janelas									
	densa					esparsa				
	3x3	4x4	5x5	6x6	7x7	3x3	5x5	7x7	9x9	11x11
10%	0.0000	0.0000	0.0010	0.0568	0.0966	0.0331	0.0000	0.0392	0.0451	0.0476
30%	0.0000	0.0000	0.0007	0.0056	0.0146	0.0331	0.0000	0.0383	0.0123	0.0371
40%	0.0000	0.0000	0.0003	0.0073	0.0272	0.0331	0.0000	0.0449	0.0214	0.0494
50%	0.0000	0.0000	0.0005	0.0099	0.0367	0.0331	0.0000	0.0452	0.0199	0.0562

Tabela 20: Média MCC na classificação de títulos do conjunto de dados TIME

	janelas									
	densa					esparsa				
	3x3	4x4	5x5	6x6	7x7	3x3	5x5	7x7	9x9	11x11
10%	0.0000	-0.0015	-0.0147	0.0281	0.0649	-0.0371	0.0000	-0.0177	0.0202	-0.0050
30%	0.0000	-0.0014	-0.0122	-0.0186	-0.0148	-0.0371	0.0000	-0.0190	-0.0087	-0.0215
40%	0.0000	0.0000	-0.0024	-0.0027	0.0109	-0.0371	0.0000	-0.0061	0.0151	0.0018
50%	0.0000	-0.0001	-0.0015	0.0069	0.0251	-0.0371	0.0000	-0.0053	0.0263	0.0121

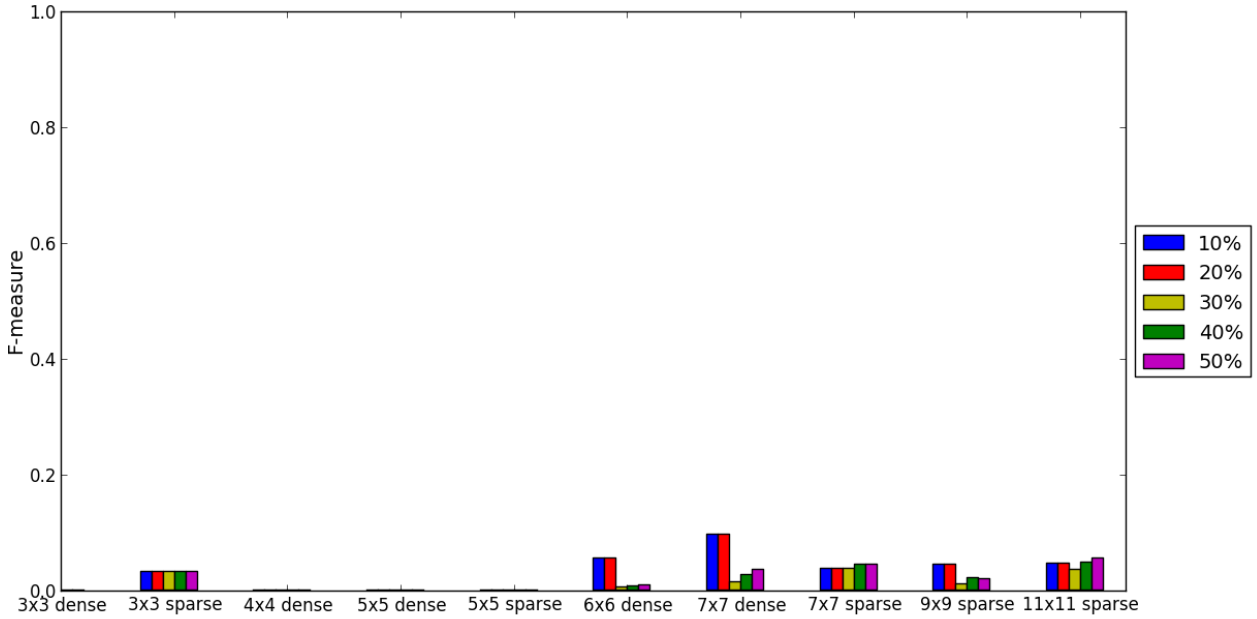

Figura 20: TIME: Classificação de títulos

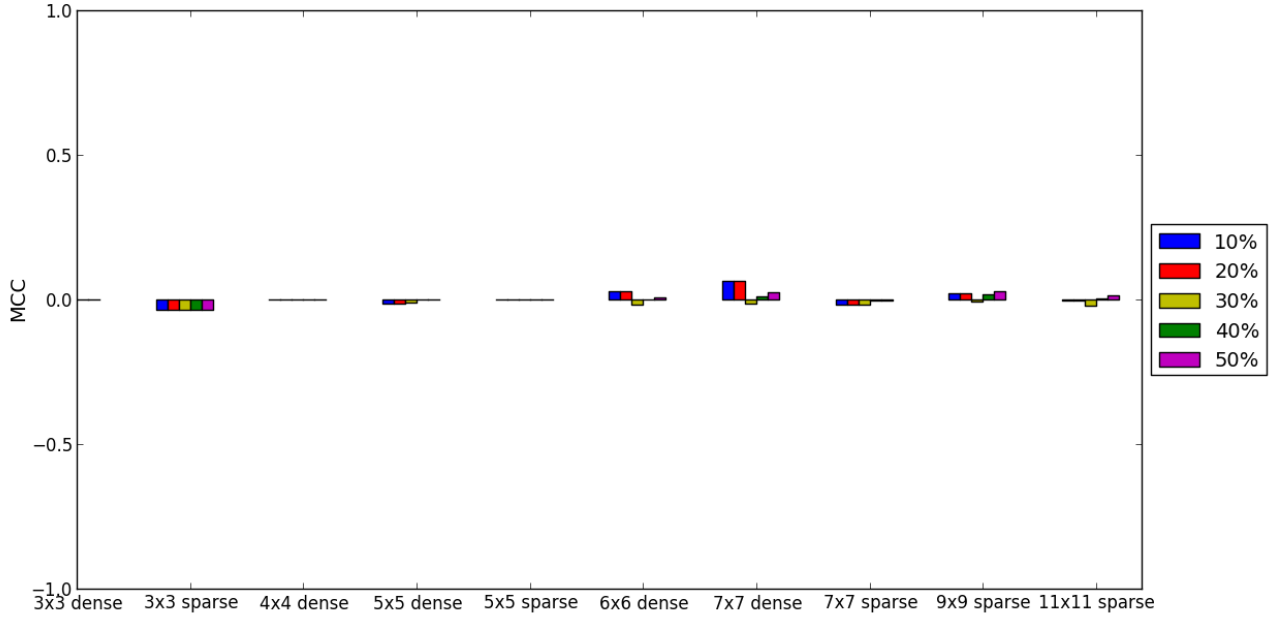

Figura 21: TIME: Classificação de títulos

6.2 Imagens finais

As tabelas 21, 22, 23, 24 e 25 apresentam as duplas de imagens segmentada e ideal para cada uma das imagens do conjunto de teste CACM. As tabelas 26, 27, 28 e29 contém as imagens da TIME. A imagem segmentada exibida foi obtida utilizando o operador morfológico de melhor F-measure (janela 9x9 esparsa com maior número de exemplos de treinamento). A cor azul representa regiões de parágrafo, verde para títulos e vermelho para marcar o que sobrou.

Tabela 21: Segmentação da imagem 689

Ideal

number of references) follows a geometric distribution with parameter p_i.

If accesses to an object are in fact correlated, then the object's IAT distribution will deviate from the geometric; so to measure correlation we introduce a metric that is very sensitive to this deviation. The *coefficient of variation* (CV) of a distribution is its standard deviation divided by its mean. To form a metric for a given trace, we take an average of IAT-CV over all references in the trace, as described in [4].

For the geometric distribution with parameter p_i, the CV is

$$\sqrt{1 - p_i}.$$

In Web reference streams, in which even the most heavily accessed objects have a very low probability of reference (generally much less than 1%), the expected IAT-CV in the case of no temporal correlation is very close to one. Therefore, in Web reference streams, CV values close to unity suggest that reference patterns are close to the IRM (contain little temporal correlation); while values larger than one represent a distribution with large relative variance, and so suggest the presence of strong inter-reference correlations.

	Filtering	Aggregation	Disaggregation
Popularity	Increases entropy	Decreases entropy, especially near servers	Little effect
Correlation	Decreases IAT-CV	Little effect	Decreases IAT-CV especially near clients

Summary of the effects of the different transformations on the two components of temporal locality.

Thus, IAT-CV is an effective metric for capturing temporal correlation. In a manner similar to normalized entropy, the importance of correlation in a reference stream can be measured by its effect on hit ratio in a LRU cache. When a trace is scrambled (removing correlations) the resulting hit ratio tends to decrease; in [4] we find this decrease is strongly correlated with IAT-CV.

Exploring Stream Locality

So far, we have been devoted to decomposing the complexity of Web systems along two axes: the transformations operating on Web streams have been decomposed into aggregation, disaggregation, and filtering; and the locality property of request streams has been decomposed into popularity and correlation. Using this decomposition, we can begin to attack the underlying problem, namely the systemwide engineering of the Web. Organizing the various processes of the system along these two axes yields a set of tractable analyses that can ultimately be recombined into a systemwide view. The idea is to consider how each transformation operates on each source of locality; we organize our findings in the table here. The results in this table are derived from measurements of Web traces, experimental evaluation of transformations of Web traces, and analytic considerations, as described in [4].

Filtering. Filtering by a cache, under commonly used cache replacement policies like LRU and least frequently used (LFU), tends to remove both components of locality. It removes popularity (increases entropy) because highly popular objects are more likely to be found in the cache; and it tends to remove correlation (decreases IAT-CV) because recently referenced objects are more likely to be found in the cache.

Aggregation. Aggregation of streams coming from distinct upstream sources tends to increase locality, especially near servers. This occurs because entropy decreases, while IAT-CV changes very little. Entropy decreases because the popularity of documents in the merged stream is generally more skewed than in the component streams being merged. This surprising effect, observed in empirical traces, occurs because globally popular documents tend to occur in each component stream, while unpopular documents do not. This effect is most pronounced near servers, where the largest number of independent streams are being merged.

Disaggregation. Disaggregation into separate streams tends to reduce locality, but its effect is only pronounced near clients. Disaggregation has little effect on entropy; this seems to be because resulting downstream components tend to maintain skewed object popularity approximately like the original stream. This is consistent with the many studies that have shown that even among objects on a single Web server, Zipf's Law is quite pronounced. Disaggregation does tend to reduce IAT-CV, but this effect is only pronounced when disaggregation occurs close to the client. At most other places in the Web system there is little correlation in either incoming or outgoing streams.

Location in the Web of Streams. Applying these insights to the Web system, we can begin to understand how locality changes as a function of location in the system. Referring back to Figure 1(b), we say that a component is near clients if it receives requests from relatively few clients, and sends requests to relatively many servers; and if the situation is reversed, the component is near servers. We can then ask how

Segmentada

number of references) follows a geometric distribution with parameter p_i.

If accesses to an object are in fact correlated, then the object's IAT distribution will deviate from the geometric; so to measure correlation we introduce a metric that is very sensitive to this deviation. The *coefficient of variation* (CV) of a distribution is its standard deviation divided by its mean. To form a metric for a given trace, we take an average of IAT-CV over all references in the trace, as described in [4].

For the geometric distribution with parameter p_i, the CV is

$$\sqrt{1 - p_i}.$$

In Web reference streams, in which even the most heavily accessed objects have a very low probability of reference (generally much less than 1%), the expected IAT-CV in the case of no temporal correlation is very close to one. Therefore, in Web reference streams, CV values close to unity suggest that reference patterns are close to the IRM (contain little temporal correlation); while values larger than one represent a distribution with large relative variance, and so suggest the presence of strong inter-reference correlations.

	Filtering	Aggregation	Disaggregation
Popularity	Increases entropy	Decreases entropy, especially near servers	Little effect
Correlation	Decreases IAT-CV	Little effect	Decreases IAT-CV especially near clients

Summary of the effects of the different transformations on the two components of temporal locality.

Thus, IAT-CV is an effective metric for capturing temporal correlation. In a manner similar to normalized entropy, the importance of correlation in a reference stream can be measured by its effect on hit ratio in a LRU cache. When a trace is scrambled (removing correlations) the resulting hit ratio tends to decrease; in [4] we find this decrease is strongly correlated with IAT-CV.

Exploring Stream Locality

So far, we have been devoted to decomposing the complexity of Web systems along two axes: the transformations operating on Web streams have been decomposed into aggregation, disaggregation, and filtering; and the locality property of request streams has been decomposed into popularity and correlation. Using this decomposition, we can begin to attack the underlying problem, namely the systemwide engineering of the Web. Organizing the various processes of the system along these two axes yields a set of tractable analyses that can ultimately be recombined into a systemwide view. The idea is to consider how each transformation operates on each source of locality; we organize our findings in the table here. The results in this table are derived from measurements of Web traces, experimental evaluation of transformations of Web traces, and analytic considerations, as described in [4].

Filtering. Filtering by a cache, under commonly used cache replacement policies like LRU and least frequently used (LFU), tends to remove both components of locality. It removes popularity (increases entropy) because highly popular objects are more likely to be found in the cache; and it tends to remove correlation (decreases IAT-CV) because recently referenced objects are more likely to be found in the cache.

Aggregation. Aggregation of streams coming from distinct upstream sources tends to increase locality, especially near servers. This occurs because entropy decreases, while IAT-CV changes very little. Entropy decreases because the popularity of documents in the merged stream is generally more skewed than in the component streams being merged. This surprising effect, observed in empirical traces, occurs because globally popular documents tend to occur in each component stream, while unpopular documents do not. This effect is most pronounced near servers, where the largest number of independent streams are being merged.

Disaggregation. Disaggregation into separate streams tends to reduce locality, but its effect is only pronounced near clients. Disaggregation has little effect on entropy; this seems to be because resulting downstream components tend to maintain skewed object popularity approximately like the original stream. This is consistent with the many studies that have shown that even among objects on a single Web server, Zipf's Law is quite pronounced. Disaggregation does tend to reduce IAT-CV, but this effect is only pronounced when disaggregation occurs close to the client. At most other places in the Web system there is little correlation in either incoming or outgoing streams.

Location in the Web of Streams. Applying these insights to the Web system, we can begin to understand how locality changes as a function of location in the system. Referring back to Figure 1(b), we say that a component is near clients if it receives requests from relatively few clients, and sends requests to relatively many servers; and if the situation is reversed, the component is near servers. We can then ask how

Tabela 22: Segmentação da imagem 692

Ideal

Timelines of Investor Relations Data at Corporate Web Sites

ONLINE DATA FOR INVESTORS IS OFTEN STALE, EVEN WHEN OF HIGH QUALITY. HOW CAN THIS SITUATION BE IMPROVED?

In recent years Securities and Exchange Commission (SEC) regulators have promoted the widespread and speedy dissemination of financial information to all users. The SEC Web site provides the following statement regarding its EDGAR archives of downloadable company financial reports and other filings (www.sec.gov/edgar/aboutedgar.htm):

"Its primary purpose is to increase the efficiency and fairness of the securities market for the benefit of investors, corporations, and the economy by *accelerating* the receipt, acceptance, dissemination, and analysis of time-sensitive corporate information filed with the agency." [emphasis added]

In October 2000, the SEC Regulation FD (fair disclosure) became effective. Although it requires companies to disseminate important investor relations (IR) information via press releases, Regulation FD specifically encourages them to use the Internet to accomplish broad and rapid dissemination [1]. The Sarbanes-Oxley Act, signed into law in July 2002, requires larger companies to accelerate the filing of their Forms 10-Q and 10-K. In addition, these firms will be required to disclose in Form 10-K whether they provide these reports at their Web sites "as soon as reasonably practicable" after filing them with the SEC [8].

Corporate IR personnel also are vitally interested in using the Internet to rapidly disseminate IR information. The Standards of Practice for Investor Relations [10] states:

"Information should be released in a manner designed to reach the widest public audience possible, including the individual investor. Companies should encourage the use of multiple technologies to disseminate information."

Corporate Web sites are especially suitable for distributing a wide variety of IR data, including analyst conference calls and manager presentations, since information can be posted in multiple formats (text, graphics, audio, and video) and languages.

Clearly, the rapid and widespread distribution of IR information via technology is desirable, both from the social (SEC) and corporate (investor relations) perspectives. Use of corporate Web sites for this purpose is an important activity with a relatively short history. Several studies have investigated

BY MICHAEL ETTREDGE AND JOHN GERDES, JR.

Segmentada

Timelines of Investor Relations Data at Corporate Web Sites

ONLINE DATA FOR INVESTORS IS OFTEN STALE, EVEN WHEN OF HIGH QUALITY. HOW CAN THIS SITUATION BE IMPROVED?

In recent years Securities and Exchange Commission (SEC) regulators have promoted the widespread and speedy dissemination of financial information to all users. The SEC Web site provides the following statement regarding its EDGAR archives of downloadable company financial reports and other filings (www.sec.gov/edgar/aboutedgar.htm):

"Its primary purpose is to increase the efficiency and fairness of the securities market for the benefit of investors, corporations, and the economy by *accelerating* the receipt, acceptance, dissemination, and analysis of time-sensitive corporate information filed with the agency." [emphasis added]

In October 2000, the SEC Regulation FD (fair disclosure) became effective. Although it requires companies to disseminate important investor relations (IR) information via press releases, Regulation FD specifically encourages them to use the Internet to accomplish broad and rapid dissemination [1]. The Sarbanes-Oxley Act, signed into law in July 2002, requires larger companies to accelerate the filing of their Forms 10-Q and 10-K. In addition, these firms will be required to disclose in Form 10-K whether they provide these reports at their Web sites "as soon as reasonably practicable" after filing them with the SEC [8].

Corporate IR personnel also are vitally interested in using the Internet to rapidly disseminate IR information. The Standards of Practice for Investor Relations [10] states:

"Information should be released in a manner designed to reach the widest public audience possible, including the individual investor. Companies should encourage the use of multiple technologies to disseminate information."

Corporate Web sites are especially suitable for distributing a wide variety of IR data, including analyst conference calls and manager presentations, since information can be posted in multiple formats (text, graphics, audio, and video) and languages.

Clearly, the rapid and widespread distribution of IR information via technology is desirable, both from the social (SEC) and corporate (investor relations) perspectives. Use of corporate Web sites for this purpose is an important activity with a relatively short history. Several studies have investigated

BY MICHAEL ETTREDGE AND JOHN GERDES, JR.

Tabela 23: Segmentação da imagem 695

Tabela 24: Segmentação da imagem 802

Tabela 25: Segmentação da imagem 803

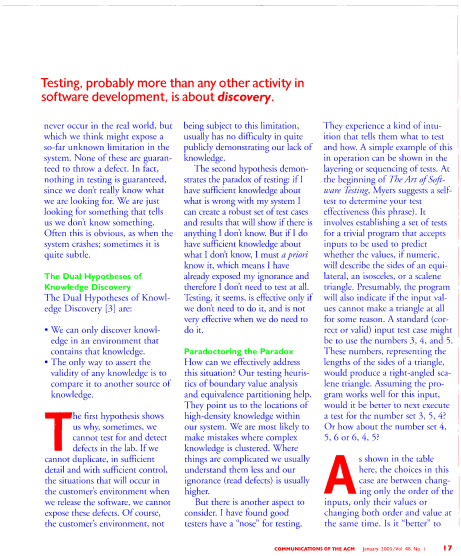

Tabela 26: Segmentação da imagem 783

Ideal

Segmentada

Tabela 27: Segmentação da imagem 784

Ideal


Commentary | Peter Beinart

Chainsaw Diplomacy

The Iraq war has spelled the end for muscular moralism in U.S. foreign policy. Here's what should replace it

Five Years in Iraq
For a brief history of the war including podcasts, photos and graphics visit time.com/iraq

WHEN AMERICA INVADED IRAQ FIVE years ago, most of the people who set U.S. foreign policy believed two things. First, they believed that the U.S. military could not lose. From Panama to Kosovo, the Gulf War to Afghanistan, America had been on a wartime winning streak since the late 1980s. Defeat in Vietnam seemed about as relevant as the War of 1812. Second, the policymakers believed that people in Iraq wanted the U.S. to win. Hadn't the Poles and Czechs celebrated when the Americans defeated the Soviets? Hadn't Afghans cheered the overthrow of the Taliban? Swirling in the air in 2003 was an intoxicating blend of militarism and moralism. U.S. troops would destroy Saddam, and Iraqi gratitude would take care of the rest.

Five years later, that combination has blown apart. John McCain is open to bombing Iran, but he doesn't claim the Iranians will be thankful for it. Barack Obama wants to restore America's good name, but not with the 82nd Airborne. For the most part, militarists and moralists now occupy separate camps. In the coming years, America will try to export its values and may well use military force. But it won't try to do both at the same time.

In many ways, this is what happened after Vietnam. Underlying that war were the beliefs that the communists in North Vietnam couldn't withstand U.S. military might and that the noncommunists in South Vietnam wanted to be saved. The war shattered both assumptions. On the left, Jimmy Carter responded by making human rights the centerpiece of his foreign policy: America would stand up for liberty—but not militarily. Conservatives insisted that had more military force been used in Vietnam, the U.S. would have won. But as the world's attitude toward the U.S. changed, they abandoned the conceit that when America took up arms, other nations would cheer.

This gulf between moralism and militarism narrowed in the 1980s and '90s. Under Ronald Reagan, conservatives grew more optimistic about exporting American values as they saw democracy spread in the Third World. And under Bill Clinton, liberals became more warlike, backing humanitarian interventions in Haiti, Bosnia and Kosovo.

Today, however, it's the '70s all over again. Republicans still assume that force—or at least the credible threat of it—is all that regimes like Iran's understand. But you don't hear many conservatives echoing the grand Wilsonianism of Bush's Second Inaugural, in which he claimed that "America's vital interests and our deepest beliefs are now one." The fastest-growing species on the foreign-policy right is what *National Review* editor Rich Lowry calls "to hell with them" hawks: conservatives who don't care how non-Americans run their societies as long as they don't threaten the U.S.

Among Democrats, hawkishness is out of fashion, but humanitarianism remains strong. In a *Foreign Affairs* article last summer, Obama argued that many around the world associate Bush's freedom talk with "war, torture and forcibly imposed regime change." His answer: help freedom's march with money, not arms.

That makes sense. Moralism and military force are both necessary to U.S. foreign policy, but the former shouldn't ride the latter into battle. The U.S. military can help stop ethnic cleansing, as it did in Bosnia and Kosovo, or safeguard the world's oil supplies, as it did in the first Gulf War, but it's not designed to build democracy. You can't do open heart surgery with a chainsaw.

Building decent, liberal societies requires strengthening parts of the U.S. government that don't carry guns. While America's military patrols the world, U.S. embassies increasingly cower behind barbed wire, disconnected from the societies they need to understand and help. America doesn't need to abandon the fervor that five years ago helped propel it into a disastrous war; it needs to redirect it. Muscular moralism has had its day. The test now is whether America can separate the two—carrying a big stick for self-defense but using less blunt instruments to improve the world. ■

Militarists and moralists now occupy separate camps. America will still try to export its values, and it may well use military force. But it won't try to do both at the same time

TIME columnist Beinart is a senior fellow at the Council on Foreign Relations

28

TIME March 31, 2008

Segmentada


Commentary | Peter Beinart

Chainsaw Diplomacy

The Iraq war has spelled the end for muscular moralism in U.S. foreign policy. Here's what should replace it

Five Years in Iraq
For a brief history of the war including podcasts, photos and graphics visit time.com/iraq

WHEN AMERICA INVADED IRAQ FIVE years ago, most of the people who set U.S. foreign policy believed two things. First, they believed that the U.S. military could not lose. From Panama to Kosovo, the Gulf War to Afghanistan, America had been on a wartime winning streak since the late 1980s. Defeat in Vietnam seemed about as relevant as the War of 1812. Second, the policymakers believed that people in Iraq wanted the U.S. to win. Hadn't the Poles and Czechs celebrated when the Americans defeated the Soviets? Hadn't Afghans cheered the overthrow of the Taliban? Swirling in the air in 2003 was an intoxicating blend of militarism and moralism. U.S. troops would destroy Saddam, and Iraqi gratitude would take care of the rest.

Five years later, that combination has blown apart. John McCain is open to bombing Iran, but he doesn't claim the Iranians will be thankful for it. Barack Obama wants to restore America's good name, but not with the 82nd Airborne. For the most part, militarists and moralists now occupy separate camps. In the coming years, America will try to export its values and may well use military force. But it won't try to do both at the same time.

In many ways, this is what happened after Vietnam. Underlying that war were the beliefs that the communists in North Vietnam couldn't withstand U.S. military might and that the noncommunists in South Vietnam wanted to be saved. The war shattered both assumptions. On the left, Jimmy Carter responded by making human rights the centerpiece of his foreign policy: America would stand up for liberty—but not militarily. Conservatives insisted that had more military force been used in Vietnam, the U.S. would have won. But as the world's attitude toward the U.S. changed, they abandoned the conceit that when America took up arms, other nations would cheer.

This gulf between moralism and militarism narrowed in the 1980s and '90s. Under Ronald Reagan, conservatives grew more optimistic about exporting American values as they saw democracy spread in the Third World. And under Bill Clinton, liberals became more warlike, backing humanitarian interventions in Haiti, Bosnia and Kosovo.

Today, however, it's the '70s all over again. Republicans still assume that force—or at least the credible threat of it—is all that regimes like Iran's understand. But you don't hear many conservatives echoing the grand Wilsonianism of Bush's Second Inaugural, in which he claimed that "America's vital interests and our deepest beliefs are now one." The fastest-growing species on the foreign-policy right is what *National Review* editor Rich Lowry calls "to hell with them" hawks: conservatives who don't care how non-Americans run their societies as long as they don't threaten the U.S.

Among Democrats, hawkishness is out of fashion, but humanitarianism remains strong. In a *Foreign Affairs* article last summer, Obama argued that many around the world associate Bush's freedom talk with "war, torture and forcibly imposed regime change." His answer: help freedom's march with money, not arms.

That makes sense. Moralism and military force are both necessary to U.S. foreign policy, but the former shouldn't ride the latter into battle. The U.S. military can help stop ethnic cleansing, as it did in Bosnia and Kosovo, or safeguard the world's oil supplies, as it did in the first Gulf War, but it's not designed to build democracy. You can't do open heart surgery with a chainsaw.

Building decent, liberal societies requires strengthening parts of the U.S. government that don't carry guns. While America's military patrols the world, U.S. embassies increasingly cower behind barbed wire, disconnected from the societies they need to understand and help. America doesn't need to abandon the fervor that five years ago helped propel it into a disastrous war; it needs to redirect it. Muscular moralism has had its day. The test now is whether America can separate the two—carrying a big stick for self-defense but using less blunt instruments to improve the world. ■

Militarists and moralists now occupy separate camps. America will still try to export its values, and it may well use military force. But it won't try to do both at the same time

TIME columnist Beinart is a senior fellow at the Council on Foreign Relations

28

TIME March 31, 2008

Tabela 28: Segmentação da imagem 785

Ideal


nary rate," says EMI's Hands. Keen to keep it alive, he is mulling changes to the way EMI's artists are rewarded. Out could go generous advances for some artists—"an excuse for us to lose more," he calls such payments. Instead, some expect him to experiment with salaries or even day rates for artists cloistered in the studio.

Would artists buy this kind of shift? Jon Webster, chief executive of the London-based Music Managers Forum, is not so sure. Far from spoiling musicians, he says, "most personal advances are to keep people alive." Squeezing out an album is an unpredictable affair, and regular pay checks might strike some artists as an unwelcome reminder to hurry up. "Creators rarely want to be sitting here watching the clock," Webster says. "The creative process doesn't work like that."

Too often, it doesn't produce money-spinning discs, either. More mature music fans might still pay up for a CD; some 2 million people outside North America bought last fall's *Long Road out of Eden*, for instance, the first studio album from the Eagles in decades. But supermarket muscle has driven down the retail price of compact discs. The only U.S. store selling that Eagles CD was Wal-Mart, for the bargain price of $11.88. The average price of a CD in Europe dropped by 4% between 2003 and 2006, according to PricewaterhouseCoopers. One way to maintain price levels is to offer deluxe products that pair a standard CD with a fancy book, live recording or DVD. Radiohead figured that out: aside from its pay-what-you-want download offer, the band flogged a special-edition box set of

'What we are saying to artists is: The current model is broken. Unless we find a new model, new music is dead.'

—GUY HANDS, EMI CHAIRMAN

In Rainbows for $80 a piece. And a repackaged, "deluxe" version of *Back To Black*, bundling Winehouse's 2006 album with bonus tracks, shot to the top of Britain's album charts just this month.

Wringing more out of plastic discs won't be enough to secure the record companies' futures, though. More pressing is the need to sharpen strategies for the digital market. Record companies were slow to turn on to digital; Doug Morris, the boss of Universal Music, once slammed MP3 players as little more than "repositories for stolen music." But last year those companies saw their revenues from digital sales hit an estimated $2.9 billion, up almost eightfold since 2004. However, that's not exactly the fortissimo it may appear to be. The 38%-annual growth in digital sales last year was less than half the increase seen in 2006. Music companies, says JupiterResearch's Mulligan, "are at a stage where they cannot afford to be as chancy as before" when it comes to distributing their wares.

That means easing restrictions on how downloads can be used, and on what kind of devices. You'll still need a whizzy Apple gadget to hear most of the music available from iTunes, but Amazon last September began selling tracks in the U.S. in a format compatible with most digital music players. Its catalogue of 3 million songs—culled from all four majors—will be available outside the U.S. later this year; European music fans unable to wait can from this month download such unrestricted tracks by Warner Music and EMI artists from 7digital, a U.K. music site.

To ease the pressure on their revenues, record companies may paradoxically have to offer more for free. Today's music consumers shell out hundreds of dollars on MP3 players, but they spend an average of just $20 a year on downloads. To the crucial teenage market, paying for music is as outdated as picking up a newspaper. But companies can get something in return for giving them music. Advertising-supported free music services such as Last.fm pay the major record companies from ad revenue; in return, their users can stream the companies' music for nothing. Such outlets offer record companies the chance to build a relationship with younger fans in the hope those users will later migrate to more lucrative products such as music DVDs. Cellphone users can also expect to get months of free access to a catalogue of songs. Nokia will launch its Comes With Music service later this year, reimbursing artists and their labels from expected new sales of its music-compatible phones; a similar service, available through Korean giant LG, will come out in the summer. The first record company to offer its music for both these services? Universal, led by the once skeptical Morris.

Innovation like that could also help to strangle music piracy: some 20 billion files were downloaded illegally in 2006. The music business has called on Internet Service Providers (ISPs), which host that traffic, to do more to choke it off, and an agreement was reached in France late last year requiring ISPs to stop large-scale copyright infringers. But to shake off its blues, the record business must itself continue to break old habits. Saying yes to rehab is a start, but returning to health is going to take a sustained dose of discipline and imagination. ■

Realigning the Stars. The

GOING SOLO
Record labels shuddered as some 40% of Radiohead fans paid an average of $6 to download its DIY album *In Rainbows* in the month after its release; a CD version later topped U.S. and U.K. charts

MATERIAL GIRL
Tour promoter Live Nation gets a slice of Madonna's concert and merchandise sales as part of a $120 million deal. As CD sales shrink, record labels hope similar arrangements will fill the shortfall

DIAL M FOR MUSIC
Mobile phones accounted for almost half of all digital music sales in the first six months of 2007. New free-download services, such as Nokia's Comes With Music, should further boost that share

TIME March 31, 2008

49

Segmentada


nary rate," says EMI's Hands. Keen to keep it alive, he is mulling changes to the way EMI's artists are rewarded. Out could go generous advances for some artists—"an excuse for us to lose more," he calls such payments. Instead, some expect him to experiment with salaries or even day rates for artists cloistered in the studio.

Would artists buy this kind of shift? Jon Webster, chief executive of the London-based Music Managers Forum, is not so sure. Far from spoiling musicians, he says, "most personal advances are to keep people alive." Squeezing out an album is an unpredictable affair, and regular pay checks might strike some artists as an unwelcome reminder to hurry up. "Creators rarely want to be sitting here watching the clock," Webster says. "The creative process doesn't work like that."

Too often, it doesn't produce money-spinning discs, either. More mature music fans might still pay up for a CD; some 2 million people outside North America bought last fall's *Long Road out of Eden*, for instance, the first studio album from the Eagles in decades. But supermarket muscle has driven down the retail price of compact discs. The only U.S. store selling that Eagles CD was Wal-Mart, for the bargain price of $11.88. The average price of a CD in Europe dropped by 4% between 2003 and 2006, according to PricewaterhouseCoopers. One way to maintain price levels is to offer deluxe products that pair a standard CD with a fancy book, live recording or DVD. Radiohead figured that out: aside from its pay-what-you-want download offer, the band flogged a special-edition box set of

'What we are saying to artists is: The current model is broken. Unless we find a new model, new music is dead.'

—GUY HANDS, EMI CHAIRMAN

In Rainbows for $80 a piece. And a repackaged, "deluxe" version of *Back To Black*, bundling Winehouse's 2006 album with bonus tracks, shot to the top of Britain's album charts just this month.

Wringing more out of plastic discs won't be enough to secure the record companies' futures, though. More pressing is the need to sharpen strategies for the digital market. Record companies were slow to turn on to digital; Doug Morris, the boss of Universal Music, once slammed MP3 players as little more than "repositories for stolen music." But last year those companies saw their revenues from digital sales hit an estimated $2.9 billion, up almost eightfold since 2004. However, that's not exactly the fortissimo it may appear to be. The 38%-annual growth in digital sales last year was less than half the increase seen in 2006. Music companies, says JupiterResearch's Mulligan, "are at a stage where they cannot afford to be as chancy as before" when it comes to distributing their wares.

That means easing restrictions on how downloads can be used, and on what kind of devices. You'll still need a whizzy Apple gadget to hear most of the music available from iTunes, but Amazon last September began selling tracks in the U.S. in a format compatible with most digital music players. Its catalogue of 3 million songs—culled from all four majors—will be available outside the U.S. later this year; European music fans unable to wait can from this month download such unrestricted tracks by Warner Music and EMI artists from 7digital, a U.K. music site.

To ease the pressure on their revenues, record companies may paradoxically have to offer more for free. Today's music consumers shell out hundreds of dollars on MP3 players, but they spend an average of just $20 a year on downloads. To the crucial teenage market, paying for music is as outdated as picking up a newspaper. But companies can get something in return for giving them music. Advertising-supported free music services such as Last.fm pay the major record companies from ad revenue; in return, their users can stream the companies' music for nothing. Such outlets offer record companies the chance to build a relationship with younger fans in the hope those users will later migrate to more lucrative products such as music DVDs. Cellphone users can also expect to get months of free access to a catalogue of songs. Nokia will launch its Comes With Music service later this year, reimbursing artists and their labels from expected new sales of its music-compatible phones; a similar service, available through Korean giant LG, will come out in the summer. The first record company to offer its music for both these services? Universal, led by the once skeptical Morris.

Innovation like that could also help to strangle music piracy: some 20 billion files were downloaded illegally in 2006. The music business has called on Internet Service Providers (ISPs), which host that traffic, to do more to choke it off, and an agreement was reached in France late last year requiring ISPs to stop large-scale copyright infringers. But to shake off its blues, the record business must itself continue to break old habits. Saying yes to rehab is a start, but returning to health is going to take a sustained dose of discipline and imagination. ■

Realigning the Stars. The

GOING SOLO
Record labels shuddered as some 40% of Radiohead fans paid an average of $6 to download its DIY album *In Rainbows* in the month after its release; a CD version later topped U.S. and U.K. charts

MATERIAL GIRL
Tour promoter Live Nation gets a slice of Madonna's concert and merchandise sales as part of a $120 million deal. As CD sales shrink, record labels hope similar arrangements will fill the shortfall

DIAL M FOR MUSIC
Mobile phones accounted for almost half of all digital music sales in the first six months of 2007. New free-download services, such as Nokia's Comes With Music, should further boost that share

TIME March 31, 2008

49

Tabela 29: Segmentação da imagem 786

Ideal

BOOKS

The Jihadi Next Door.

BY ARYN BAKER

AHMED OMAR SAEED SHEIKH was the kind of guy you could have taken home to Mom. Smart and friendly, he once jumped in front of a train in a London tube station to rescue a fallen commuter. But he also, in the name of the Islamist cause, gleefully threatened a hostage with decapitation in 1994. That hostage survived, but Danny Pearl, the *Wall Street Journal* Pakistan correspondent whom Sheikh is charged with kidnapping in January 2002, did not. The video of Pearl's beheading can still be found on the Internet (though the identity of the actual knife wielder remains unknown). How does someone like Sheikh—"the kindest, most gentle person you could meet," according to his brother—turn terrorist?

In *Leaderless Jihad*, the latest book by the author of 2004's *Understanding Terror Networks*, forensic psychiatrist Marc Sageman attempts to unravel the psychological profile of Islamist terrorists. Like his earlier book, *Leaderless Jihad* discredits conventional wisdom about terrorists by eschewing anecdotes and conjecture in favor of hard data and statistics. And statistically, the enemy is us.

"It is easy to view terrorists as alien creatures who exist outside normal patterns of social interaction," he writes. But the sobering reality is that they don't. Sociopaths do not make capable terrorists—they seldom take orders and are rarely willing to sacrifice their lives for a larger goal. Many terrorists, on the other hand, share qualities with ordinary, law-abiding people: they can be cooperative, goal-oriented and intelligent, even if emotionally wrought. Often the start of their radicalization can be traced to a scrupulous moral outrage—not an irrational hatred or base prejudice.

Radical Muslims become bombers, Sageman argues, when the causes of their anger—the Israeli occupation of Palestinian land, the U.S. invasion of Iraq—come to be perceived as part of a wholesale war against Islam. This feeling of being under attack may be amplified by personal experience of discrimination and then validated by exchanges with like-minded friends, family members and Internet users before being converted into action by "al-Qaeda." Not, as Sageman puts it,

Many terrorists share qualities with ordinary people: they can be cooperative, goal-oriented and intelligent

Public enemy *Sheikh's brother called him "the kindest, most gentle person you could meet"*

"al-Qaeda Central" (made up of those who have sworn an oath of loyalty to Osama bin Laden) but al-Qaeda the informal network, mobilizing radicalized Islamists around the world without any contact with bin Laden at all.

Al-Qaeda Central, says Sageman, is on the wane, its leaders dead or on the run and increasingly isolated. It is the informal al-Qaeda—born after the attacks on Sept. 11 and exploding into raging adolescence after the U.S. invasion of Iraq in 2003—that is the real threat, waging the "leaderless jihad" of the book's title chapter.

Poverty and lack of opportunity are not necessarily the factors that drive young men to commit violence in al-Qaeda's name. (Sheikh was middle class and educated at a private school.) "They view themselves as warriors willing to sacrifice themselves for the sake of building a better world," Sageman explains, "and this gives meaning to their lives." They are also younger and less visible, blending in with the Western societies they grew up in.

Because of security crackdowns, they are unable to reach out to al-Qaeda's original leadership, but they can access jihadi Internet forums for guidance and bomb-making expertise. The Madrid train bombings of 2004, which killed 191 commuters, are an example of an atrocity committed by such young men. The attacks were an "offering to al-Qaeda Central leaders for ... admission into the ranks of global Islamist terrorism," Sageman writes.

The solution to Islamic terrorism, as the author sees it, is genuine peace in the Palestinian territories and an immediate U.S. withdrawal from Iraq, depriving jihadis of their ability to wage a moral war. "The presence of even one American soldier ... will trump any goodwill policy the United States attempts to carry out in the Middle East," he writes. He also recommends an end to the offering of rewards, to the publication of most wanted lists and to the staging of press conferences that proclaim the capture of top terrorists, since jihadis regard all these as badges of honor. It would be better, Sageman says, to treat terrorists like common criminals.

None of Sageman's solutions are new or achievable soon, and not everyone agrees that they would work. But it isn't a forensic psychiatrist's job to come up with counterterrorist strategy. It is his job to offer a cogent alternative to the "Why do they hate us?" hand-wringing that dominates much writing about the terrorist mind-set, and Sageman has done that with great clarity. ■

Segmentada

BOOKS

The Jihadi Next Door.

BY ARYN BAKER

AHMED OMAR SAEED SHEIKH was the kind of guy you could have taken home to Mom. Smart and friendly, he once jumped in front of a train in a London tube station to rescue a fallen commuter. But he also, in the name of the Islamist cause, gleefully threatened a hostage with decapitation in 1994. That hostage survived, but Danny Pearl, the *Wall Street Journal* Pakistan correspondent whom Sheikh is charged with kidnapping in January 2002, did not. The video of Pearl's beheading can still be found on the Internet (though the identity of the actual knife wielder remains unknown). How does someone like Sheikh—"the kindest, most gentle person you could meet," according to his brother—turn terrorist?

In *Leaderless Jihad*, the latest book by the author of 2004's *Understanding Terror Networks*, forensic psychiatrist Marc Sageman attempts to unravel the psychological profile of Islamist terrorists. Like his earlier book, *Leaderless Jihad* discredits conventional wisdom about terrorists by eschewing anecdotes and conjecture in favor of hard data and statistics. And statistically, the enemy is us.

"It is easy to view terrorists as alien creatures who exist outside normal patterns of social interaction," he writes. But the sobering reality is that they don't. Sociopaths do not make capable terrorists—they seldom take orders and are rarely willing to sacrifice their lives for a larger goal. Many terrorists, on the other hand, share qualities with ordinary, law-abiding people: they can be cooperative, goal-oriented and intelligent, even if emotionally wrought. Often the start of their radicalization can be traced to a scrupulous moral outrage—not an irrational hatred or base prejudice.

Radical Muslims become bombers, Sageman argues, when the causes of their anger—the Israeli occupation of Palestinian land, the U.S. invasion of Iraq—come to be perceived as part of a wholesale war against Islam. This feeling of being under attack may be amplified by personal experience of discrimination and then validated by exchanges with like-minded friends, family members and Internet users before being converted into action by "al-Qaeda." Not, as Sageman puts it,

Many terrorists share qualities with ordinary people: they can be cooperative, goal-oriented and intelligent

Public enemy *Sheikh's brother called him "the kindest, most gentle person you could meet"*

"al-Qaeda Central" (made up of those who have sworn an oath of loyalty to Osama bin Laden) but al-Qaeda the informal network, mobilizing radicalized Islamists around the world without any contact with bin Laden at all.

Al-Qaeda Central, says Sageman, is on the wane, its leaders dead or on the run and increasingly isolated. It is the informal al-Qaeda—born after the attacks on Sept. 11 and exploding into raging adolescence after the U.S. invasion of Iraq in 2003—that is the real threat, waging the "leaderless jihad" of the book's title chapter.

Poverty and lack of opportunity are not necessarily the factors that drive young men to commit violence in al-Qaeda's name. (Sheikh was middle class and educated at a private school.) "They view themselves as warriors willing to sacrifice themselves for the sake of building a better world," Sageman explains, "and this gives meaning to their lives." They are also younger and less visible, blending in with the Western societies they grew up in.

Because of security crackdowns, they are unable to reach out to al-Qaeda's original leadership, but they can access jihadi Internet forums for guidance and bomb-making expertise. The Madrid train bombings of 2004, which killed 191 commuters, are an example of an atrocity committed by such young men. The attacks were an "offering to al-Qaeda Central leaders for ... admission into the ranks of global Islamist terrorism," Sageman writes.

The solution to Islamic terrorism, as the author sees it, is genuine peace in the Palestinian territories and an immediate U.S. withdrawal from Iraq, depriving jihadis of their ability to wage a moral war. "The presence of even one American soldier ... will trump any goodwill policy the United States attempts to carry out in the Middle East," he writes. He also recommends an end to the offering of rewards, to the publication of most wanted lists and to the staging of press conferences that proclaim the capture of top terrorists, since jihadis regard all these as badges of honor. It would be better, Sageman says, to treat terrorists like common criminals.

None of Sageman's solutions are new or achievable soon, and not everyone agrees that they would work. But it isn't a forensic psychiatrist's job to come up with counterterrorist strategy. It is his job to offer a cogent alternative to the "Why do they hate us?" hand-wringing that dominates much writing about the terrorist mind-set, and Sageman has done that with great clarity. ■

7 Conclusão

Observamos comportamentos diferentes na classificação de parágrafos e títulos. A quantidade de imagens demonstrou-se menos relevante na classificação parágrafos do que na classificação de títulos. Isto se deve a maior quantidade de exemplos por página de texto de parágrafo do que de títulos.

O tamanho da janela é o fator mais sensível, tanto para a qualidade quanto para o tempo de processamento. Janelas maiores porém esparsas apresentaram os melhores resultados, sendo o melhor deles observado para janelas 9x9 esparsas, atingindo F-measure de 0,96 para CACM e 0,93 para a TIME.

Porém nem sempre a maior janela produz o melhor resultado. As janelas 11x11 desempenharam pior que as 9x9. Quanto maior a janela, mais exemplos são necessários. Podemos ver que em janelas maiores o tamanho do conjunto de treinamento possui maior influência na qualidade. Com janelas até 5x5 a quantidade de exemplos quase não altera a qualidade ou até piora.

Exemplos ruins também podem comprometer a qualidade do operador. Fontes muito parecidas para títulos e outros tipos de texto podem fornecer exemplos contraditórios, ou seja, hora um certo padrão consta como título hora não. Podemos ver um exemplo deste fenômeno na imagem 23 onde o texto à direita foi classificado como título por possuir características de título. Parte do motivo por este problema ocorrer é decorrente da decisão de testarmos apenas dois tipos de região (parágrafo e título). Possivelmente, caso tivéssemos classificados outros tipos de texto, poderíamos obter resultados melhores na etapa de consensualização.

Uma outra possível melhoria seria trabalhar com imagens redimensionadas (reduzidas), fazendo com que os títulos ficassem menores, cabendo melhor dentro das janelas utilizadas.

Não pudemos testar janelas maiores que 11x11 pois o tempo de processamento cresce muito rapidamente tornando o processo muito custoso.

A comparação com outros métodos foi comprometida pela escolha das regiões a serem segmentadas. No artigo [8] vemos os resultados dos principais métodos para textos em geral e não parágrafos e títulos separadamente. Um outro problema é o método para avaliação, que utiliza polígono isotéticos, como proposto no artigo [7]. Teríamos que realizar algum tipo de transformação que definiria polígonos em torno dos pixeis de uma certa região, assim como fez o método descrito em [9].

Acreditamos que o método proposto pode ser empregado na extração de texto de documentos. Porém, diversos ajustes de otimização seriam necessários para criar uma ferramenta utilizável em situações práticas. O treinamento dos operadores é muito lento e aplicação também.

8 Apêndice

8.1 Algoritmo de Otsu para binarização

Implementar e avaliar cada algoritmo binarizador vai além do escopo deste trabalho, portanto escolhemos um bom algoritmo segundo os resultados obtidos em [10]. Como o próprio artigo aponta, não foi encontrado um método que apresentasse desempenho superior em todas os cenários de teste realizados.

Os requisitos para a escolha foram o da independência de supervisionamento e parametrização. Caso o algoritmo demandasse ajustes específicos de acordo com a imagem, o seu uso comprometeria a promissa de automatização. Dentre a lista de soluções com esta característica, escolhemos o algoritmo de Otsu [11], por ser de fácil implementação e apresentar resultados satisfatórios nos experimentos realizados.

O algoritmo de Otsu encontra um nível de cinza t tal que a soma ponderada da variância

dentro das classes $\mathbb{F} = \{x\colon f(x) \geq t\}$ (foreground) e $\mathbb{B} = \{x\colon f(x) < t\}$ (background) seja minimizada, ou seja,

$$t = argmin\{w_{\mathbb{B}}\sigma^2_{\mathbb{B}} + w_{\mathbb{F}}\sigma^2_{\mathbb{F}}\} \tag{8}$$

onde $w_{\mathbb{B}} = \frac{|\mathbb{B}|}{|E|}$ e $w_f = \frac{|\mathbb{F}|}{|E|}$ são os pesos respectivamente do background e foreground e $\sigma^2_{\mathbb{B}}$ e $\sigma^2_{\mathbb{F}}$ são as variâncias das classes.

A tabela 31 apresenta um passo a passo do algoritmo aplicado à figura 30.

Tabela 30: Imagem original em escala de cinza e correspondente binarizada com $t = 50\%$.

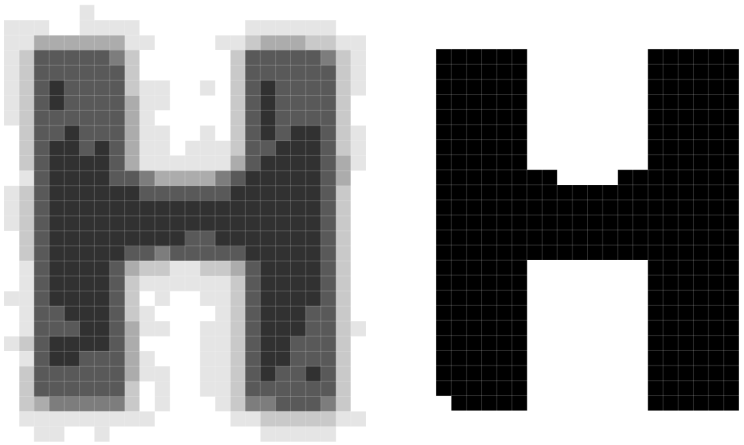

Como podemos notar, para $t = 50\%$ atingimos o menor valor de $\sigma^2_w \approx 512693389$. Neste caso o limiar coincide com o único vale no histograma, porém isto nem sempre será válido. Algumas imagens não possuem vales bem definidos. Este algoritmo não se baseia no formato do histograma mas sim na coesão intra classe e na separabilidade das classes.

Uma desvantagem de utilizar este algoritmo é a influência da média de todo os pixeis da imagem. Isto pode fazer com que o limiar ótimo para a página toda não seja o mesmo que o de dentro de uma janela.

8.2 Implementação

Todos os experimentos foram realizados utilizando scripts ruby e python para automatizar a tarefa. Também utilizamos a biblioteca ImageMagick e bibliotecas para manipulação de XML.

O processo todo consistiu em baixar a base de dados do PRImA, processá-las gerando as entradas para o TRIOS, construir os operadores, aplicá-los, consensualizar e extrair métricas.

Este trabalho tem como objetivo provar um conceito: avaliar a aplicabilidade de operadores morfológicos à segmentação de página. Logo o código gerado não é destino a aplicações comerciais.

- sample_generator.rb produz todos os conjuntos de imagens para treinamento e teste, ou seja, ele transforma todas as imagens e XMLs da base de dados original em entradas apropriadas para as ferramentas que utilizamos.

Tabela 31: Estágios da execução do algoritmo de Otsu.

original	25%	37,5%	50%	62,5%	75%	87,5%
						
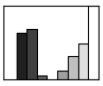	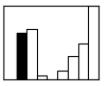	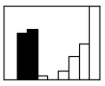	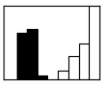	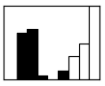	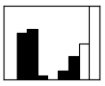	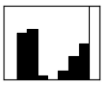
$w_{\mathbb{B}}$	0.1931	0.4015	0.4179	0.4532	0.5479	0.6969
$\mu_{\mathbb{B}}$	34.00	51.64	53.61	61.37	83.08	112.56
$\sigma^2_{\mathbb{B}}$	7.27	288.58	372.94	1054.08	3128.03	5656.37
$w_{\mathbb{F}}$	0.80	0.59	0.58	0.54	0.45	0.30
$\mu_{\mathbb{F}}$	184.87	225.55	229.03	233.95	243.79	255.0
$\sigma^2_{\mathbb{F}}$	5799.89	1409.01	1006.11	673.10	255.43	0.0
σ^2_w	21495165144	967521582	512693389	595067475	4269882800	17660993341

- imgset_training_gen.rb gera e aplica todos os 200 operadores utilizados nos experimentos. Utiliza os executáveis trios_build e trios_apply fornecidos pelo TRIOS.
- measures.py extrai todas as estatísticas apresentadas na seção 6.
- consensus.py faz a união das segmentações realizadas pelo apply_all.rb
- merge.py cria imagens segmentadas coloridas para visualização.

Referências

[1] Rangachar Kasturi, Lawrence O'Gorman, and Venu Govindaraju. Document image analysis: A primer. *Sadhana*, 27(1):3–22, 2002.

[2] Nina Sumiko Tomita. Programação automática de máquinas morfológicas binárias baseada em aprendizado pac. Master's thesis, Departamento de Ciência da Computação, Instituto de Matemática e Estatística, April 1996. This work has been supported by ProTeM-CC/CNPq throught the AnIMoMat project, contract 680067/94-9.

[3] Igor dos Santos Montagner, Roberto Hirata Jr, and Nina ST Hirata. Trios-an open source toolbox for training image operators from samples.

[4] A. Antonacopoulos, D. Bridson, C. Papadopoulos, and S. Pletschacher. A realistic dataset for performance evaluation of document layout analysis, 2009.

[5] Stefan Pletschacher and Apostolos Antonacopoulos. The page (page analysis and ground-truth elements) format framework. In *Proceedings of the 20th International Conference on Pattern Recognition (ICPR2010), Istanbul, Turkey, August 23-26, 2010*, pages 257–260. IEEE-CS, 2010.

[6] C Clausner, S Pletschacher, and A Antonacopoulos. Aletheia-an advanced document layout and text ground-truthing system for production environments. In *Document Analysis and Recognition (ICDAR), 2011 International Conference on*, pages 48–52. IEEE, 2011.

[7] A. Antonacopoulos and D. Bridson. Performance analysis framework for layout analysis methods. *Document Analysis and Recognition, International Conference on*, 2:1258–1262, 2007.

[8] *10th International Conference on Document Analysis and Recognition, ICDAR 2009, Barcelona, Spain, 26-29 July 2009*. IEEE Computer Society, 2009.

[9] Michael A. Moll and Henry S. Baird. Document content inventory and retrieval. In *In Proc., IAPR 9th Int'l Conf. on Document Analysis and Recognition (ICDAR2007*, 2007.

[10] Mehmet Sezgin and Bülent Sankur. Survey over image thresholding techniques and quantitative performance evaluation. *Journal of Electronic Imaging*, 13(1):146–168, January 2004.

[11] Nobuyuki Otsu. A Threshold Selection Method from Gray-level Histograms. *IEEE Transactions on Systems, Man and Cybernetics*, 9(1):62–66, January 1979.