

H-Metric: Uma métrica para a caracterização de conjuntos de imagens via homogeneização baseada em consultas KNN

Wellington Manoel da Silva e José Fernando Rodrigues Júnior
Universidade Federal de São Carlos, Sorocaba – Universidade de São Paulo, São Carlos (ICMC)
Rod. João Leme dos Santos, Km 110 – Av. Trabalhador são-carlense, 400
CEP 18052-780, Sorocaba, SP – CEP 13560-970, São Carlos, SP

Email: welingtonms@hotmail.com, junio@icmc.usp.br

Abstract—Precision-Recall is the main metric for evaluating content-based image retrieval techniques. However, it does not provide an ample perception of the properties of an image dataset immerse in a metric space. In this work, we describe an alternative metric named *H-Metric*, which is determined along a sequence of controlled modifications of the homogeneity characteristics of the classes of an image dataset. The result is a process that measures how hard it is to deal with a set of images in respect to content-based retrieval, offering support in the task of analyzing *distance function-features extractor configurations*.

Resumo—A Precisão-Revocação é a principal métrica usada para a avaliação de técnicas de recuperação de imagens baseada em conteúdo. No entanto, ela não provê uma percepção ampla das propriedades de um conjunto de imagens imerso em um espaço métrico. Neste trabalho, descreve-se uma métrica alternativa denominada *H-Metric*, determinada ao longo de uma sequência controlada de modificações das características de homogeneidade das classes de um conjunto de imagens. O resultado é um processo que mede a dificuldade apresentada por um dado conjunto no que se refere à recuperação de imagens baseada em conteúdo, auxiliando na análise de configurações *função distância-extrator de características*.

Keywords—recuperação de imagens baseada em conteúdo; espaços métricos; Precisão-Revocação;

I. INTRODUÇÃO

A recuperação de dados baseada em conteúdo é uma das técnicas mais importantes para a indexação de dados não dimensionais, como imagens, sons e vídeos. Tais técnicas se baseiam no conceito de espaço métrico, uma abstração matemática que permite que dados de qualquer natureza sejam embutidos em um espaço dentro do qual pode-se fazer busca. Espaços métricos se baseiam em extração de características, funções distância e métodos de acesso métrico, fatores que podem determinar diferentes configurações de indexação de dados. As possibilidades de definição de espaços métricos são inúmeras, o que leva a diferentes soluções para um mesmo problema de indexação. Por esta razão, é necessário um método para se medir a eficiência das diferentes soluções propostas. A

maneira mais usual de se medir tal eficiência é a métrica denominada Precisão e Revocação [1].

O uso da Precisão-Revocação ocorre em configurações onde técnicas de recuperação de dados baseada em conteúdo são projetadas e propostas à comunidade, a qual deve verificar a eficiência do que se propõe – incluindo extratores de características, funções distância e métodos de acesso métrico, entre outras. Nestas circunstâncias, a Precisão-Revocação fornece parâmetros para a avaliação dos resultados alcançados.

Além das metodologias envolvidas na definição de um espaço métrico, um dos fatores que mais influencia o cálculo da métrica de Precisão-Revocação é o conjunto de dados sobre o qual é realizada a indexação métrica. No caso de imagens, em aplicações de recuperação objetivando semelhança, conjuntos em que as imagens apresentam alto grau de homogeneidade visual tendem a apresentar melhores resultados em gráficos de Precisão-Revocação; ao passo que em conjuntos em que as imagens são mais heterogêneas visualmente tendem a apresentar gráficos indicando menor eficiência. Em outras palavras, diferentes conjuntos de imagens determinam diferentes graus de dificuldade quando o objetivo é a recuperação de imagens satisfazendo à semelhança visual; pode-se dizer que alguns conjuntos são “mais difíceis” do que outros.

Apesar do impacto que o conjunto de imagens indexadas tem na avaliação da Precisão-Revocação e no próprio projeto de técnicas de indexação, não existem métricas que informem ao pesquisador o quão desafiador um dado conjunto de imagens é, ou mesmo, qual é a comparação entre diferentes conjuntos de imagens. Este fato pode dificultar a pesquisa de técnicas de recuperação de imagens baseada em conteúdo, pois leva aos seguintes problemas:

- falta de uma referência numérica e concisa com relação ao conjunto de imagens, dificultando uma avaliação plena dos resultados da Precisão-Revocação;
- inexistência de um critério preciso para a escolha de conjuntos de imagens de teste;
- dificuldade em se traçar equivalência entre diferentes

conjuntos de imagens;

- ônus adicional na escolha de conjuntos de imagens, os quais devem ser verificados individualmente;
- complexidade na descrição das características de um dado conjunto de imagens em veículos de divulgação científica.

No contexto destes problemas, o presente trabalho descreve a metodologia *H-Metric*, uma maneira de se descrever as propriedades de um conjunto de imagens dentro da problemática definida pela recuperação de dados suportada por indexação métrica.

II. TRABALHOS RELACIONADOS

Quando se usa um conjunto de imagens em experimentos de indexação métrica, depende-se muito das propriedades dos dados para se ter resultados considerados bons ou ruins em um gráfico de Precisão-Revocação. Pode acontecer, por exemplo, que uma dada configuração (extrator de características e função distância) apresente ótimos resultados para um dado conjunto de imagens; todavia, o conjunto usado apresentaria bons resultados para um grande número de outras configurações. Isto acontece em conjuntos de imagens cujas características extraídas definem agrupamentos bem definidos quando seus elementos são considerados no contexto de um espaço métrico, não sendo um desafio árduo sua correta indexação. Em outros casos, é possível que um pesquisador desenvolva novas configurações métricas e, ao testar sua metodologia em um conjunto de imagens, percebe resultados não satisfatórios na forma de curvas de Precisão-Revocação inferiormente abauladas. No entanto, o conjunto de imagens que foi usado apresentaria resultados ruins para um grande número de configurações métricas. Isto acontece com conjuntos que, em um espaço métrico, não apresentam qualquer homogeneidade (agrupamentos bem definidos) com relação às suas classes. De fato, segundo [2], a Precisão-Revocação é tendenciosa, pois trata-se de uma métrica superficial, havendo a necessidade de métricas que trabalhem com maior profundidade medindo-se também a tendência embutida no conjunto de dados.

Nos casos descritos no parágrafo anterior, há um prejuízo no que se refere ao processo de pesquisa e desenvolvimento. No primeiro, pode ocorrer que técnicas pouco eficientes aparentem potenciais além do que efetivamente suportam [3]. No segundo, técnicas promissoras podem ser abandonadas precocemente. Em ambos, o processo de aperfeiçoamento de uma dada configuração métrica é prejudicado, pois o pesquisador não recebe parâmetros adequados para avaliar sua metodologia. Do modo como é usada, a Precisão-Revocação muitas vezes é uma grandeza sem referencial, não se sabe exatamente se ela se refere a baixas ou altas magnitudes. Deste modo,

o presente trabalho encaixa-se na linha defendida por Berger [4], segundo a qual a validade de um experimento deve ser condicionada ao conhecimento do quanto o resultado esperado (sucesso) é, *a priori*, presente nos dados de teste.

III. CONCEITOS

A. Extração de Características

A primeira tarefa necessária para a indexação de dados não dimensionais é transformá-los em um formato apropriado, constituído de dimensões. No domínio de imagens, este passo requer um processo denominado de *extração de características*, o qual é orientado principalmente a características de cor, forma e textura. Isto é, deve-se transformar as imagens em uma representação numérica que corresponde a um vetor $x = \{x_0, x_1, \dots, x_{n-1}\}$ de n números representativos intrínsecos aos dados originais. Exemplos clássicos são o histograma de cores [5] e os coeficientes alcançados usando-se a transformada de Fourier [6]. Assim, ao longo deste texto, o termo extração de características refere-se à fórmula geral $f : D \rightarrow \mathfrak{D}$, onde D é o domínio de dados e $\mathfrak{D} \subset R^n$ é o espaço de características n -dimensional.

B. Funções Distância

Após a extração de características, é necessário o uso de uma medida de similaridade, ou função distância, que mede a similaridade entre os vetores de números extraídos dos objetos de dados. A maneira mais comum de se fazer isso é considerar cada característica numérica como uma coordenada de um espaço n -dimensional e calcular a distância Euclideana entre os vetores. Outros exemplos de medidas são a City Block e a família de distâncias Minkowisk [7]. O uso de diferentes medidas de distância permite não apenas ter-se uma diversidade de escopos em espaços métricos, mas também permite a ponderação de dimensões específicas, adicionando interesse semântico na recuperação de dados.

C. Espaços Métricos

Uma vez que um extrator de características e uma função distância foram definidos, pode-se estabelecer um espaço métrico. Um espaço métrico é um par $M = \langle \mathfrak{D}, \delta() \rangle$, onde \mathfrak{D} é o domínio dos dados a serem indexados e $\delta : \mathfrak{D} \times \mathfrak{D} \rightarrow \mathbb{R}^+$ é uma função que associa uma distância a qualquer par $o_i, o_j \in \mathfrak{D}$. Dados três elementos o_i, o_j e $o_k \in \mathfrak{D}$, o par $M = \langle \mathfrak{D}, \delta() \rangle$ define um espaço métrico quando a função $\delta()$ satisfaz aos seguintes axiomas:

- 1) **Simetria:** $\delta(o_i, o_j) = \delta(o_j, o_i)$
- 2) **Não negatividade:** $0 < \delta(o_i, o_j) < \infty$, se $o_i \neq o_j$, e $\delta(o_i, o_i) = 0$
- 3) **Desigualdade triangular:** $\delta(o_i, o_j) \leq \delta(o_i, o_k) + \delta(o_k, o_j)$

Neste contexto, $\delta()$, a função de distância métrica, é a responsável pelo cálculo da similaridade entre os objetos do domínio em questão. Quanto mais similares são os objetos, menor será o valor retornado; bem como quanto mais dissimilares os objetos, maior o valor retornado. Com isso, as operações de recuperação de dados (consultas) tornam-se intuitivas dentro de espaços métricos a partir do conceito de similaridade.

D. Consulta aos k -vizinhos mais próximos

Sobre um espaço métrico, torna-se possível a realização de consultas por similaridade. Em tais consultas, dado um elemento de interesse – o centro da consulta, deseja-se recuperar os elementos do conjunto de imagens que têm menores distâncias (maior similaridade) para com este elemento. As duas consultas por similaridade básicas são a consulta pelos vizinhos mais próximos e a consulta por abrangência. A consulta pelos vizinhos mais próximos a definida a seguir:

Definição 1 (consulta pelo vizinho mais próximo): dado um objeto de consulta o_q representado por seu vetor de características $f(o_q)$, e dado o domínio de elementos D , o vizinho mais próximo de D refere-se ao elemento o_n estabelecido por $NNQuery(o_q) = \{o_n \in D | \forall o_i \in D, \delta(f(o_q), f(o_n)) \leq \delta(f(o_q), f(o_i))\}$. Por exemplo: “encontre a imagem em D que é a mais parecida com a foto do papa”.

A extrapolação da definição 1 para k vizinhos mais próximos, $k \geq 1$, é direta e define o que se denomina na literatura de *consulta aos k -vizinhos mais próximos*, ou $KNNQuery(o_q, k)$, que produz uma lista ordenada de elementos na qual o $(n - 1)$ -ésimo elemento está mais próximo de o_q , ou à mesma distância, que o n -ésimo elemento, $2 \leq n \leq k$.

E. Precisão-Revocação

O cálculo da Precisão-Revocação é feito usando-se conjuntos de dados pré-classificados. Em tais conjuntos, é possível a realização de consultas (recuperação de dados) de maneira que seus resultados possam ser verificados simplesmente examinando-se as classes dos objetos retornados, e comparando-as com as classes já conhecidas de um dado conjunto. A métrica da Precisão-Revocação decorre do fato de que, quando uma consulta é realizada, as informações por ela retornadas podem ou não ter relevância a um dado elemento de interesse, de acordo com critérios estabelecidos para um dado domínio. Esta relevância é o que determina a pré-classificação dos dados; assim, o que se quer avaliar é a satisfação da relevância esperada durante a realização de consultas.

A Precisão-Revocação pode ser formalizada como se segue. Para uma dada consulta centrada em um elemento

de interesse o_q , considere D o domínio de dados, R o conjunto de elementos relevantes (esperados), A o conjunto de elementos retornados pela consulta, e R_A o conjunto de elementos retornados pela consulta que são relevantes.

$$P = \frac{R_A}{A} \quad (1)$$

$$R = \frac{R_A}{R} \quad (2)$$

Dado o contexto de uma consulta, define-se como Precisão a razão entre o número de elementos relevantes retornados ($|R_A|$) e o número de elementos retornados na consulta ($|A|$) – equação 1. Revocação define-se como a razão entre o número de elementos relevantes retornados ($|R_A|$) e o número de elementos relevantes ($|R|$) – equação 2. A Precisão-Revocação é medida ao longo do espectro da quantidade de elementos relevantes retornados em uma dada consulta, considerando-se um conjunto A com cardinalidade suficiente para que se obtenha Revocação aproximada a 1 (100% dos elementos relevantes) e Precisão aproximada a $|R|/|D|$. Usualmente, realiza-se uma consulta para cada elemento de um subconjunto significativo dos elementos pré-classificados; cada consulta considerando $|A| = |D|$ elementos. O conjunto de medidas de Precisão-Revocação das múltiplas consultas, então, é agregado por meio de média aritmética.

IV. A MÉTRICA H-METRIC

No contexto apresentado nas seções I e II, a metodologia que se propõe é o uso da Precisão-Revocação não apenas sobre a configuração primária de um conjunto de imagens, mas também extrapolando-se seu princípio de funcionamento ao longo de uma sequência de modificações controladas das classes de um dado conjunto de imagens.

Neste trabalho, inicialmente, realiza-se uma sequência de consultas pelos vizinhos mais próximos – a partir do centróide de uma dada classe – usando-se os resultados para o cálculo da Precisão-Revocação de maneira tradicional. Durante as consultas, prossegue-se identificando os elementos retornados que reduziram o desempenho da indexação métrica; nesta primeira iteração identificam-se apenas tais elementos, os quais foram retornados segundo uma consulta aos $t = 1$ elementos mais próximos. Em seguida, tais elementos têm suas classes redefinidas para que não prejudiquem o desempenho medido pela Precisão-Revocação. Isto é, o elemento mais próximo de cada centro de consulta passa a ter a mesma classe do centro de consulta como sua classe, independentemente da sua classe original. Após esta iteração, o desempenho da Precisão-Revocação aumenta. O que se faz, então, é prosseguir com a redefinição da classe dos elementos mais próximos do centro de consulta considerando $t =$

2, 3, ..., |D|. A cada iteração, mede-se o desempenho da Precisão-Revocação, o qual aumenta até que em um determinado momento, para $t < |D|$, sua curva aproxima-se do ideal.

O processo de redefinição das classes dos vizinhos mais próximos, descrita no parágrafo anterior, é denominada aqui de *processo de homogeneização*. Esta denominação se deve pois o que se observa é a definição de agrupamentos mais bem definidos dentro do espaço métrico, o que aumenta o desempenho da Precisão-Revocação. A idéia, portanto, é tornar o desafio da recuperação de imagens progressivamente mais “fácil”, monitorando-se o desempenho alcançado em cada passo. No momento em que há uma convergência para um desempenho máximo, defini-se que o valor de t utilizado corresponde à complexidade do conjunto de imagens, o qual será considerado “h-difícil”, onde $h = t$. O que se observa é que diferentes conjuntos de dados convergem para uma curva de Precisão-Revocação máxima mais rapidamente do que outros e, portanto, cada conjunto tem seu valor de h característico. Formalmente:

Dado um centro de consulta o_q e um domínio de imagens D , a t -homogeneização se refere à redefinição da classe dos elementos da lista ordenada $KNNQuery(o_q, t) = \langle o_1, o_2, \dots, o_t \rangle$, tal que $Classe(o_i) \neq Classe(o_q), \forall o_i \in KNNQuery(o_q, t), 1 \leq i \leq t$. Considera-se o processo de homogeneização convergente quando:

$$\int_0^1 (P_t(R_t)) dR_t - \int_0^1 (P_{t+1}(R_{t+1})) dR_{t+1} \leq 0.01 \quad (3)$$

onde $P(R)$ é uma função polinomial contínua que interpola os pontos de Precisão-Revocação. Isto é, quando não há variação significativa entre dois gráficos consecutivos de Precisão-Revocação considera-se que um desempenho máximo foi alcançado.

V. EXPERIMENTOS

Foram realizados experimentos com três conjuntos de imagens, denominados “objetos”, “lugares” e “paisagens”, ilustrados na figura 1. Cada conjunto contém 10 classes, cada uma com 12 elementos, totalizando 360 imagens. Neste primeiro experimento foram extraídas características de cor. Mais especificamente, de cada imagem foi calculado o histograma de cores e de cada histograma extraíram-se: média aritmética, desvio padrão, suavidade, distorção, uniformidade, e entropia. Tais características são denominadas, de modo geral, estatísticas de primeira-ordem e, dado um histograma, são calculadas como descrito a seguir.

O n -ésimo momento da média é dado por:

$$\mu_n = \sum_{i=0}^{L-1} (Z_i - m)^n p(Z_i) \quad (4)$$

onde Z_i se refere à i -ésima intensidade observada em um canal de cor (vermelho, azul, verde, ou cinza), $p(Z_i)$ é a frequência relativa da intensidade Z_i , L é o número de diferentes níveis de intensidade, e m é a média das intensidades observadas, dada por:

$$m = \sum_{i=0}^{L-1} Z_i p(Z_i) \quad (5)$$

Assim, um valor $p(Z_i)$ é uma estimativa da probabilidade de ocorrência da intensidade Z_i , de maneira que todo o histograma pode ser entendido como uma função densidade de probabilidade. A partir daí, calculam-se as demais estatísticas de primeira ordem:

O desvio padrão, ou contraste médio:

$$\sigma = \sqrt{\mu_2(Z) - m^2} = \sqrt{\sigma^2} \quad (6)$$

onde $\mu_2(Z)$ é o segundo momento da média.

A suavidade, a qual apresenta valor 0 para intensidade constante e valor próximo de 1 para intensidades muito oscilantes:

$$R = 1 - 1/(1 + \sigma^2) \quad (7)$$

Distorção, ou terceiro momento ao redor da média, a qual se aproxima de 0 para histogramas simétricos, tende a valores positivos para histogramas distorcidos para a direita, e para valores negativos para histogramas distorcidos para a esquerda:

$$\mu_3 = \sum_{i=0}^{L-1} (Z_i - m)^3 p(Z_i) \quad (8)$$

A uniformidade, a qual tende ao seu valor máximo quando todos os valores de $p(Z_i)$ são iguais, tendendo a valores mais baixos quando há maior variabilidade:

$$U = \sum_{i=0}^{L-1} p(Z_i)^2 \quad (9)$$

E a entropia, a qual dá uma idéia de aleatoriedade dos níveis $p(Z_i)$:

$$e = - \sum_{i=0}^{L-1} p(Z_i) \log_2 p(Z_i) \quad (10)$$

Considerando-se os conjuntos de imagens, pode-se afirmar que o primeiro conjunto, o dos objetos, é bastante homogêneo. Neste conjunto, os objetos de cada classe variam apenas segundo a iluminação aplicada sobre a imagem. No segundo conjunto, o de lugares, as imagens são bastante complexas do ponto de vista de forma mas, em cada classe, apresentam significativa homogeneidade de cores. Já o terceiro conjunto, o de paisagens, usa apenas tons de cinza e suas imagens são




Figura 1. Ilustração dos três conjuntos de imagens usados nos experimentos.

visualmente confusas.

Para cada conjunto foram realizadas 60 consultas pelos k vizinhos mais próximos considerando $k = 120$. Foi usada a distância Euclidiana. A partir destas consultas foram calculados 12 pontos de Precisão-Revocação, cada um correspondendo a um incremento de $1/12$ de Revocação do total de imagens. Os 60 valores calculados para cada um dos 12 pontos foram agregados usando-se média aritmética. Para cada conjunto de dados, foi realizada uma sequência de processos de homogeneização até se alcançar a condição de convergência.

Resultados

A figura 2 apresenta gráficos de Precisão-Revocação para os três grupos de imagens após trinta iterações de homogeneização, com valores $t = 10, 20, 21$, e 22 . Na sequência é possível notar que o conjunto de imagens de objetos converge com $t = 20$, sendo assim considerado 20-difícil. Já o conjunto de imagens de lugares converge com $t = 22$, o que o caracteriza como sendo 22-difícil. Já o conjunto de imagens de paisagens não converge até o valor apresentado de $t = 22$, sendo necessária a aplicação de iterações adicionais de homogeneização.

Prosseguindo, a figura 3 apresenta os gráficos de Precisão-Revocação para valores de $t = 102, 103$, e 104 . Com o valor de $t = 102$, finalmente, observa-se a convergência do conjunto de imagens de paisagens. Trata-se, portanto, de um conjunto 103-difícil, o que, para um total de 120 imagens indica que este conjunto é totalmente adverso à extração de características de cor.

Nos experimentos, os valores da H-Metric provêm uma idéia do desafio apresentado por cada conjunto, o que fornece ao pesquisador a percepção de como cada conjunto pode ser tratado e do que esperar de cada

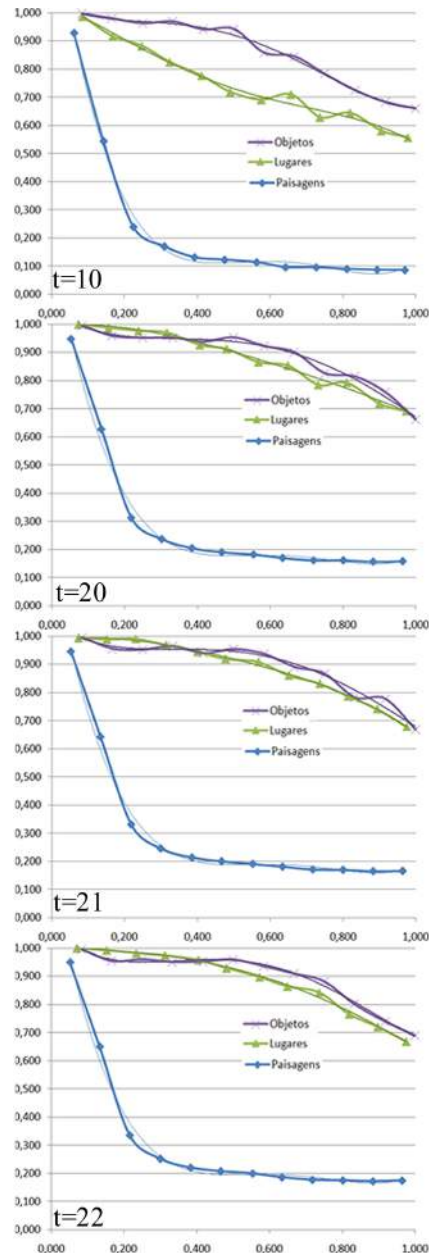


Figura 2. Gráficos de Precisão-Revocação para valores crescentes de homogeneização. Com $t = 20$ observa-se a convergência do conjunto de imagens de objetos. Com $t = 22$, observa-se a convergência do conjunto de imagens de lugares.

configuração métrica. Com a métrica, a escolha de um destes conjuntos para experimentos de recuperação de imagens baseada em conteúdo torna-se direta a partir de um único valor de referência. Com base neste valor, pode-se afirmar que os conjuntos de “objetos” e de “paisagens” devem apresentar resultados diferentes, mas sempre obedecendo a uma distância proporcional ao valor da H-Metric. Pode-se afirmar também que o conjunto de “paisagens” não deve ser considerado

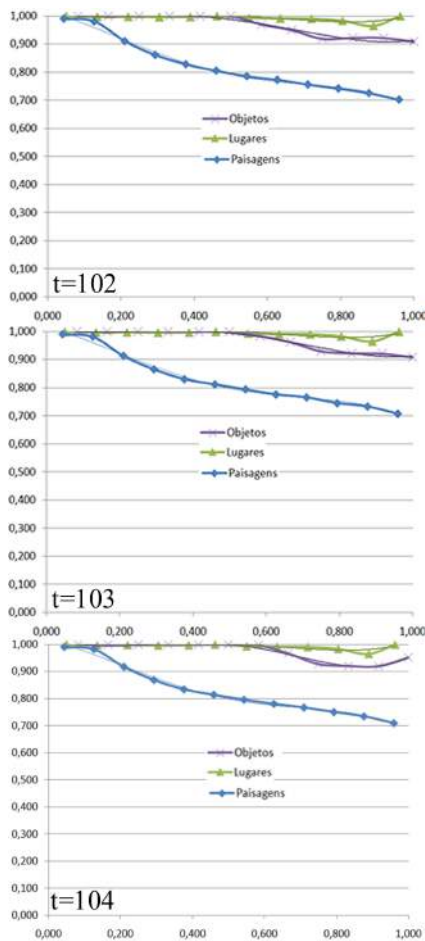


Figura 3. Gráficos de Precisão-Revocação para valores ainda maiores de homogeneização. Apenas após $t = 103$, o gráfico referente ao conjunto de imagens de paisagens converge para uma curva estável. Neste grau de homogeneização, os conjuntos de objetos e lugares alcançam um estado artificial, segundo o qual a maioria dos elementos foi re-classificada para uma mesma classe.

em configurações métricas orientadas a histogramas de cores, pois possui uma complexidade natural que impede esta abordagem.

VI. TRABALHO EM ANDAMENTO

Este trabalho é a primeira etapa do desenvolvimento de uma metodologia que objetiva analisar processos de recuperação de imagens considerando o espectro da complexidade do problema sendo tratado. Entre os objetivos ainda a serem desenvolvidos estão:

- monitoração da distribuição estatística das características dos elementos que reduzem o desempenho do sistema;
- análise do comportamento da área descrita sob a curva de Precisão-Revocação ao longo da homogeneização;
- estudo da possibilidade do uso do monitoramento da homogeneização no aperfeiçoamento de funções

distância e de extratores de características.

VII. CONCLUSÕES

Este trabalho apresentou a pesquisa e o desenvolvimento sobre um sistema de recuperação de imagens baseada em conteúdo. Para tanto, tratou-se dos temas de função distância, extração de características, avaliação de técnicas de indexação métrica, além de um completo sistema de recuperação de dados. Foram considerados três conjuntos de imagens, dos quais foram extraídas estatísticas de primeira ordem dos respectivos histogramas de cor. Para a avaliação das técnicas foi usada a métrica de Precisão-Revocação, e para desenvolvimento e realização de experimentos foi usado o sistema MetricSPlat (<http://gbdi.icmc.usp.br/~junio/MetricSPlat/index.htm>). Sobre o exercício realizado, foi desenvolvida a idéia denominada H-Metric, uma sistemática baseada em consultas pelos vizinhos mais próximos que traça gráficos de Precisão-Revocação considerando etapas progressivas de homogeneização das classes de um dado conjunto de imagens. Os resultados iniciais refletem as expectativas traçadas sobre o uso da Precisão-Revocação ao longo do espectro de configuração das classes de conjuntos de imagens pré-classificados. Como próximas etapas, deve-se considerar a análise espectral para a identificação das limitações intrínsecas apresentadas por técnicas de indexação métrica, auxiliando no refinamento de técnicas.

AKNOWLEDGEMENTS

Este trabalho teve suporte do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

REFERÊNCIAS

- [1] R. A. Baeza-Yates and B. A. Ribeiro-Neto, *Modern Information Retrieval*. ACM Press / Addison-Wesley, 1999.
- [2] L. Reeker, "Theoretic constructs and measurement of performance and intelligence in intelligent systems," in *Performance Metrics for Intelligent Systems*. National Institute of Standards and Technology, 2001.
- [3] D. M. W. Powers, "Evaluation: From precision, recall and f-factor to roc, informedness, markedness & correlation," School of Informatics and Engineering, Flinders University, Adelaide, Australia, Tech. Rep. SIE-07-001, 2007.
- [4] J. Berger, *Statistical Decision Theory and Bayesian Analysis*. Springer-Verlag, 1985.
- [5] J. C. Felipe, A. J. M. Traina, and C. Traina Jr., "Global warp metric distance: Boosting content-based image retrieval through histograms," in *IEEE International Symposium on Multimedia-ISM2005*. IEEE Press, 2005, p. 8.
- [6] D. S. Zhang and G. J. Lu, "Shape retrieval using fourier descriptors," in *Intl. Conference on Multimedia and Distance Education*, 2001, pp. 1–9.
- [7] C. C. Aggarwal, A. Hinneburg, and D. A. Keim, "On the surprising behavior of distance metrics in high dimensional spaces," in *International Conference on Database Theory (ICDT)*. Springer Verlag, 2001, pp. 420–434.