

TEMU KEMBALI CITRA BERBASIS KONTEN PADA CITRA LINTAS DOMAIN

Yaya Wihardi^{1,*}, Herbert Siregar¹, and Ali Mulyawan²

¹Departemen Pendidikan Ilmu Komputer, Universitas Pendidikan Indonesia. ²STMIK Mardira Indonesia
yayawihardi@upi.edu, herbert@upi.edu, alimuly@yahoo.com

Abstract

This research aimed to develop a cross domain content based image retrieval system by using Histogram of Oriented Gradient (HoG) features. To compute visual similarity, we use Gaussian Approximation for Fast Image Similarity (GAFIS), Online Algorithm for Scalable Image Similarity Learning (OASIS), and Hybrid method that combine both of GAFIS and OASIS. The results show that the hybrid method outperforms the others, it is because the methods could extract uniqueness of each image query and image database by utilizing Gaussian parameters from negative-set and combine it with OASIS parameters

Keywords : Image Retrieval, CBIR, Gaussian Approximation, OASIS.

TEMU KEMBALI CITRA BERBASIS KONTEN PADA CITRA LINTAS DOMAIN

Abstrak

Pada penelitian ini dilakukan proses temu kembali citra pada citra lintas domain, yang meliputi citra ke citra, sketsa ke citra, dan lukisan ke citra, dengan menggunakan fitur *Histogram of Oriented Gradient* (HoG). Adapun metode pengukuran kemiripan visual yang digunakan yaitu *Gaussian Approximation for Fast Image Similarity* (GAFIS), *Online Algorithm for Scalable Image Similarity Learning* (OASIS), dan metode *Hybrid* yang merupakan gabungan dari kedua metode GAFIS dan OASIS. Hasil eksperimen menunjukkan bahwa metode *Hybrid* memberikan unjuk kinerja yang baik dan stabil pada citra lintas domain, karena metode ini mampu melakukan ekstraksi keunikan terhadap citra kueri melalui pembobotan yang dilakukan dengan memanfaatkan parameter Gaussian dari citra negative-set yang dikombinasikan dengan parameter tuning terhadap bobot tersebut melalui pembelajaran berdasarkan algoritma OASIS.

Kata kunci: Temu Kembali Citra, CBIR, Gaussian Approximation, OASIS.

PENDAHULUAN

Temu kembali citra berbasis konten atau lebih dikenal dengan istilah *Content-based image retrieval* (CBIR) merupakan salah satu topik dalam kajian perolehan informasi dan computer vision. Secara sederhana CBIR ini merupakan proses penelusuran dan pencocokan citra kueri dengan kumpulan citra yang ada di dalam basisdata. Kemudian dari hasil pencarian tersebut, berdasarkan hasil pengukuran tingkat kemiripan (*similarity*), disajikan sejumlah citra yang diurutkan berdasarkan tingkat kemiripan tertinggi sampai yang terendah.

Saat ini telah dikembangkan banyak sistem CBIR, beberapa diantaranya sudah memiliki kemampuan yang cukup handal dalam menangani pencarian citra pada domain spesifik. Namun sistem-sistem tersebut masih memiliki performa yang kurang memuaskan jika digunakan dalam

domain yang bervariasi atau bahkan lintas domain. Sebagai contoh, sistem CBIR yang handal dalam pencarian berdasarkan citra foto, belum tentu memberikan hasil yang baik pada proses pencarian citra berdasarkan citra lukisan ataupun sketsa, padahal di dalam dunia nyata seringkali kita hanya mendapati citra kueri pada domain yang berbeda dengan hasil yang ingin kita peroleh.

Permasalahan tersebut menantang berbagai peneliti dalam CBIR untuk memecahkannya. Pendekatan yang paling populer saat ini adalah melalui pendekatan pembelajaran mesin (*machine learning*). Salah satunya dilakukan oleh (Shrivastava, Malisiewicz, Gupta, & Efros, 2011), hasilnya cukup memuaskan, namun waktu eksekusi pencarian atau penghitungan *similarity* sangat lama, sehingga kurang cocok diterapkan dalam mesin pencari. Hal ini terjadi karena proses learning dilakukan berulang setiap kali proses pencarian dilakukan. Untuk memperbaiki kekurangan

tersebut, (Gharbi, Malisiewicz, Paris, & Durand, 2012) melakukan penelitian yang berbeda. Pada penelitian tersebut learning dilakukan cukup sekali di awal (*offline-learning*) yang melibatkan metode *Gaussian Approximation*. Dari sudut pandang kecepatan, hasilnya cukup baik, namun kinerja presisi sistem menurun.

Metode lainnya yang cukup menjanjikan adalah *Online Algorithm for Scalable Image Similarity Learning (OASIS)* (Chechik, Sharma, Shalit, & Bengio, 2009). Metode ini mampu melakukan *offline-learning* dengan hasil yang cukup memuaskan, namun sayangnya metode ini tidak didesain untuk menghitung *similarity* citra pada lintas domain.

Oleh karena itu, mengingat berbagai kekurangan dan kelebihan dari masing-masing metode, dalam penelitian ini akan diujicobakan model penggabungan dari dua metode, yaitu *Gaussian-based fast image similarity* (Gharbi, Malisiewicz, Paris, & Durand, 2012) yang merupakan pengembangan dari *data driven visual similarity* dan OASIS (Chechik, Sharma, Shalit, & Bengio, 2009), sehingga diharapkan model yang dikembangkan ini dapat mewarisi keunggulan dari masing-masing metode.

Penelitian Terkait

Komponen utama penyusun sistem *content-based image retrieval* adalah metode ekstraksi fitur dan metode pengukuran kemiripan (*similarity*). Masing-masing sub komponen tersebut memiliki tingkat kesulitan tersendiri dalam proses pengembangannya.

Metode Ekstraksi Fitur

Pada citra-citra yang secara visual dipandang oleh manusia memiliki

kemiripan yang tinggi, pada kenyataannya secara teknis bisa jadi pada level raw pixel memiliki kemiripan yang sangat rendah (Shrivastava, Malisiewicz, Gupta, & Efros, 2011). Oleh karena itu, metode ekstraksi fitur yang baik harus dapat mengekstraksi informasi visual yang terkandung di dalam raw pixel tersebut. Beberapa keragaman yang membuat hal ini sulit dilakukan yaitu adanya variasi skala, orientasi, view point, maupun iluminasi (Lowe, 2004). Untuk mengatasi permasalahan tersebut telah banyak dikembangkan metode yang mampu mengekstraksi fitur citra yang invarian terhadap variasi-variasi tersebut. Beberapa metode tersebut diantaranya adalah Scale Invariant Feature Transform (SIFT) (Lowe, 2004) dan Speed-Up Robust Features (SURF) (Bay, Tuytelaars, & Gool, 2008), dan Histogram of Oriented (HoG) (Dalal & Triggs, 2005).

Metode SIFT dapat mengekstraksi dan merepresentasikan fitur dari sebuah citra yang invarian terhadap skala, orientasi, iluminasi maupun 3D view point. Secara garis besar metode ini melakukan proses Difference of Gaussian untuk mendeteksi scale space yang ekstrim sebagai keypoint, untuk kemudian dilakukan lokalisasi dan perhitungan orientasi. Namun metode ini sangat mahal dalam komputasinya, sehingga terus dilakukan upaya perbaikan.

Salah satu metode penerus SIFT adalah HoG. Metode ini cukup handal digunakan dalam domain pengenalan objek, namun sayangnya harus dilakukan proses windows scanning untuk dapat memberikan hasil yang baik, sehingga biaya komputasinya masih tetap mahal. Selain itu, metode berikutnya yang merupakan perbaikan dari SIFT adalah SURF. Metode ini diklaim memiliki kecepatan dan akurasi yang tinggi, sehingga sudah banyak

digunakan di dalam dunia industri. Namun salah satu kekurangan metode ini adalah sangat sensitif terhadap perubahan orientasi.

Metode Pengukuran Kemiripan

Terdapat banyak pendekatan untuk mengukur tingkat kemiripan visual citra. Pendekatan tradisional menggunakan fitur lokal dari sebuah citra untuk kemudian dihitung tingkat kesamaannya dengan citra lain menggunakan metode pengukuran jarak maupun metode pengukuran similarity seperti Euclidian Distance, Cosine Similarity, Structural similarity, dan lain-lain. Namun pendekatan ini kurang handal dalam melakukan pengukuran kemiripan citra yang hanya mirip secara visual namun sangat berbeda dalam struktur raw-pixel-nya, sehingga dibutuhkan pendekatan lain.

Seiring perkembangan teknologi informasi dan komunikasi data, jumlah koleksi citra yang tersedia baik di jaringan lokal maupun di jaringan internet semakin bertambah dari waktu ke waktu. Hal ini mendorong para peneliti untuk memanfaatkan jumlah data yang besar tersebut. Didorong oleh fenomena tersebut dan diikuti oleh semakin mapannya metode-metode di dalam proses pengenalan pola, hal ini menyebabkan perubahan cara pandang terhadap proses pengukuran similarity, yang semula hanya berdasarkan pada konsep jarak sekarang sedikit bergeser dan berlandaskan kepada pengenalan pola dan pembelajaran mesin (Atta, Joshi, Li, & Wang, 2008).

Salah satu metode pengukuran jarak yang menjadi inspirasi dalam pengembangan metode pengukuran berdasarkan konsep pengenalan pola dan pembelajaran mesin adalah metode pengukuran jarak Mahalanobis. Pada metode Mahalanobis dilibatkan mean dan covariance dari group data tersebut

dalam proses penghitungannya. Hal ini menginspirasi para peneliti untuk melakukan proyeksi secara linear terhadap data ke dimensi yang lebih rendah, kemudian hasil proyeksi dihitung jaraknya menggunakan euclidean distance. Dari pemikiran tersebut banyak dilahirkan metode-metode pengukuran jarak lainnya seperti pada relevant component analysis (Bar-Hillel, Hertz, Shental, & Weinshall, 2003), supervised global metric learning (Xing, Ng, Jordan, & Russell, 2003), dan large margin nearest neighbor (Weinberger, Blitzer, & Saul, 2006).

Selain itu, pengembangan metode pengukuran jarak berbasis pengenalan pola juga diinspirasi oleh metode berbasis kernel pada domain klasifikasi. Alih-alih digunakan sebagai classifier, model kernel digunakan untuk mengoptimalkan parameter penyusun fungsi pengukur jarak maupun similarity. Beberapa fungsi pengukur jarak maupun similarity yang diinspirasi metode berbasis kernel diantaranya adalah one-shot similarity (Wol, Hassner, & Taigman, 2009), data driven visual similarity (Shrivastava, Malisiewicz, Gupta, & Efros, 2011), dan Gaussian-based fast image similarity (Gharbi, Malisiewicz, Paris, & Durand, 2012). Metode berbasis kernel ini memberikan hasil yang cukup menjanjikan.

Salah satu metode berbasis kernel yang cukup handal dalam hal lintas domain adalah data driven visual similarity. Metode ini mampu mengekstraksi keunikan dari sebuah citra yang tentunya sangat bermanfaat dalam pengukuran tingkat kemiripan. Keunikan tersebut sangat erat kaitannya dengan pencarian fokus objek pada citra, dimana hanya objek tertentu saja yang menjadi fokus perhatian untuk membedakannya dengan citra lain. Hal ini selaras dengan cara manusia melihat suatu objek visual. Metode ini cukup

memberikan hasil yang menjanjikan, namun dibutuhkan sumberdaya dan waktu yang cukup tinggi untuk proses komputasinya. Untuk memperbaiki metode tersebut digunakanlah pendekatan lain yang diperkenalkan oleh Gharbi et.al.(Gharbi, Malisiewicz, Paris, & Durand, 2012) yaitu Gaussian-based fast image similarity. Metode tersebut cukup sukses untuk menurunkan waktu komputasi namun tidak mampu meningkatkan akurasi bahkan unjuk kerjanya sedikit lebih menurun.

Salah satu metode pengukuran similarity berbasis pengenalan pola lainnya yang cukup handal adalah *Online Algorithm for Scalable Image Similarity Learning (OASIS)*(Chechik, Sharma, Shalit, & Bengio, 2009). Metode ini cukup stabil digunakan untuk mengenali pola kemiripan dari data yang berjumlah besar. Namun berbeda dengan metode data driven visual similarity, metode ini belum teruji untuk mengukur kemiripan visual citra lintas domain.

METODE

Pada penelitian ini digunakan metode ekstraksi fitur *Histogram of Oriented Gradient (HoG)*, sedangkan teknik pengukuran kemiripan yang digunakan meliputi metode *Gaussian Approximation for Fast Image Similarity (GAFIS)*, *OASIS*, dan *Hybrid* yang merupakan penggabungan dari kedua metode tersebut.

Histogram of Oriented Gradient (HoG)

Histogram of Oriented Gradient (HOG) merupakan salah satu metode *feature extraction* yang cukup handal dan tidak dipengaruhi oleh perubahan orientasi citra. Metode ini diperkenalkan oleh Dalal et.al. pada tahun 2005 (Dalal & Triggs, 2005). Metode ini pada dasarnya sama dengan metode Scale

Invariant Feature Transform (SIFT) yang diperkenalkan oleh David G. Lowe (Lowe, 2004), namun pada metode ini dilakukan normalisasi *overlapping local contrast* pada blok. Hasil ekstraksi fitur HoG cukup baik untuk diproses lebih lanjut, karena masih merepresentasikan citra secara keseluruhan, berbeda dengan metode sejenis yang berbasis keypoint, dimana hanya merepresentasikan patch dari citra itu sendiri.

Pada metode ini secara garis besar dilakukan tahapan sebagai berikut:

- 1) Normalisasi nilai warna dan nilai gamma
- 2) Penghitungan gradient

Untuk menghitung gradien, dilakukan filtering pada citra dengan menggunakan kernel sebagai berikut:

$$[-1,0,1] \text{ dan } [-1,0,1]^T$$

- 3) Spatial/Orientation Binning

Pada tahap ini, hasil perhitungan *gradient* dibagi-bagi ke dalam cell yang berukuran 6x6 piksel. Kemudian dilakukan voting terhadap nilai gradien tersebut ke dalam 9 *channel* histogram orientasi yang berkisar antara 0 sampai dengan 180 derajat.

- 4) Normalisasi dan Deskripsi Blok

Langkah selanjutnya *cell-cell* tersebut kemudian dinormalisasi menggunakan *overlapping block* yang berukuran 3x3 cell. *Cell* hasil normalisasi merupakan vektor yang merepresentasikan fitur citra. Fitur yang dihasilkan tersebut berupa vektor yang mengandung nilai dan arah dari setiap blok.

Data Driven Visual Similarity(DDVS)

Data driven *visual similarity* merupakan metode pengukuran *similarity* yang diperkenalkan oleh Shrivastava et.al. (Shrivastava, Malisiewicz, Gupta, & Efros, 2011) pada tahun 2011. Metode ini melakukan analisis diskriminan terhadap citra kueri dan sekumpulan citra acak yang disebut sebagai natural world. Dimana citra kueri dianggap sebagai sample positif dan natural-world dianggap sebagai sample negative. Bobot diskriminan (w_q) yang memisahkan kedua sample tersebut digunakan sebagai bobot keunikan citra kueri yang bisa membedakannya dengan citra lainnya. Adapun fungsi *visual similarity* (S) didefinisikan sebagai perkalian antara fitur citra pembandingan dengan bobot diskriminan citra kueri (w_q).

$$S(I_q, I_p) = w_q^T I_p \quad (1)$$

dimana I_q merupakan fitur citra kueri, dan I_p merupakan fitur citra pembandingan.

Untuk melakukan analisis diskriminan ini, digunakan linear-SVM untuk menghitung nilai w_q dengan fungsi objektif sebagai berikut:

$$L(w_q) = \sum_{x_i \in \mathcal{P} \cup I_q} h(w_q^T x_i) + \sum_{x_j \in \mathcal{N}} h(-w_q^T x_j) + \lambda \|w_q\|^2 \quad (2)$$

dimana nilai $\lambda = 100$ dan fungsi hinge loss function sebagai berikut:

$$h(x) = \max(0, 1-x) \quad (3)$$

Gaussian Approximation for Fast Image Similarity (GAFIS)

Gaussian Approximation of Feature Space for Fast Image Similarity merupakan variasi dari metode *Data Driven Visual Similarity*. Metode ini diperkenalkan oleh Gharbi et.al. (Gharbi, Malisiewicz, Paris, & Durand,

2012) pada tahun 2012. Pendekatan yang digunakan dalam melakukan analisis diskriminan dalam metode ini adalah dengan menggunakan *Gaussian approximation*. Keunggulan metode ini dibanding dengan *DDVS* adalah dari tingkat kecepatannya. Metode ini jauh lebih cepat dari metode *DDVS* karena menggunakan pendekatan parametrik.

Untuk mendapatkan diskriminan antara kueri dan *natural-world* digunakan matriks kovarian dan *mean* dari *natural-world* yang dihitung menggunakan persamaan standard:

$$\Sigma = \frac{1}{n} \sum_i (x_i - \mu)(x_i - \mu)^T \quad (4)$$

dimana n merupakan jumlah data di dalam *natural-world*. *Mean* dan kovarian tersebut hanya dihitung sekali saja, sehingga pada proses-proses selanjutnya akan berjalan cepat.

Untuk menghitung bobot diskriminan yang akan digunakan dalam persamaan (1) digunakan persamaan berikut:

$$w_q = \Sigma^{-1}(q - \mu) \quad (5)$$

dimana w_q merupakan bobot diskriminan, dan q adalah vektor citra kueri.

Online Algorithm for Scalable Image Similarity Learning (OASIS)

Online Algorithm for Scalable Image Similarity Learning (OASIS) merupakan metode pengukuran *similarity* yang menggunakan parameter hasil pembelajaran dalam proses pengukurannya. Metode ini diperkenalkan oleh Chechik et.al. (Chechik, Sharma, Shalit, & Bengio, 2009) pada tahun 2009. Pembelajaran dilakukan terhadap sekumpulan data *triplet*. Misal terdapat suatu data *triplet*

yang terdiri dari p_i , p_i^+ , dan p_i^- . Data tersebut dapat diinterpretasikan bahwa pasangan p_i dan p_i^+ memiliki tingkat kemiripan yang lebih besar dibandingkan pasangan p_i dan p_i^- . Kemudian dari sekumpulan data *triplet* tersebut dilakukan pembelajaran untuk mendapatkan suatu fungsi *similarity* (S) dengan parameter W sehingga:

$$S(p_i, p_i^+) > S(p_i, p_i^-) + 1, \quad \forall p_i, p_i^+, p_i^- \in \mathcal{P} \quad (6)$$

Dimana \mathcal{P} merupakan set citra data latih, dan p merupakan representasi vektor dari masing-masing citra dengan dimensi d . Sedangkan fungsi *similarity* dengan parameter W didefinisikan sebagai berikut:

$$S_W(p_i, p_j) \equiv p_i^T W p_j \quad (7)$$

Karena p berdimensi d , dengan kata lain $p \in \mathbb{R}^d$, maka $W \in \mathbb{R}^{d \times d}$.

Untuk melakukan pembelajaran sesuai *constraint* pada persamaan (6), maka digunakan *loss function* (L_W) sebagai berikut:

$$L_W \equiv \sum_{(p_i, p_i^+, p_i^-) \in \mathcal{P}^3} l_W(p_i, p_i^+, p_i^-) \quad (8)$$

dimana,

$$l_W(p_i, p_i^+, p_i^-) \equiv \max(0, 1 - S_W(p_i, p_i^+) + S_W(p_i, p_i^-)) \quad (9)$$

Untuk meminimalkan *global loss function* L_W , maka digunakan algoritma pembelajaran sebagai berikut:

1. Inisialisasi nilai W dengan matriks identitas, $W^0 = I_{d \times d}$
2. Kemudian ambil sebuah data *triplet* p_i , p_i^+ , dan p_i^- secara random

3. Berdasarkan data *triplet* yang terambil, lakukan update bobot W dengan memecahkan permasalahan optimasi berikut:

$$W^i = \underset{W}{\operatorname{argmin}} \frac{1}{2} \|W - W^{i-1}\|_{Fro}^2 + C\xi \quad (10)$$

Subject to:

$$l_W(p_i, p_i^+, p_i^-) \leq \xi \quad (11)$$

4. Ulangi langkah tiga untuk semua set data latih.

Untuk mengukur tingkat kemiripan data *test* digunakan persamaan (7) dengan memanfaatkan parameter W hasil pembelajaran di atas.

Hybrid

Metode ini merupakan penggabungan dari metode *GAFIS* dan *OASIS*. Skenario penggabungan yang dilakukan adalah dengan mensubstitusikan bobot diskriminan (w) yang dihasilkan metode *GAFIS* (lihat persamaan 5) ke dalam persamaan *similarity* (persamaan 7) dari metode *OASIS* sebagai pengganti p_i .

$$S_w(p_i, p_j) = p_i^T \cdot W \cdot p_j$$

Substitusikan w_{p_i} ke dalam persamaan sebagai pengganti p_i , sehingga persamaan *similarity* (S_w) *OASIS* menjadi:

$$S_w(p_i, p_j) = w_{p_i}^T \cdot W \cdot p_j \quad (12)$$

dimana p_i dan p_j adalah vector citra yang dibandingkan, dan W adalah parameter hasil pembelajaran dari metode *OASIS*.

Untuk lebih jelasnya skema metode *hybrid* ini digambarkan dalam Figure 1. Dengan adanya proses ekstraksi keunikan citra yang dilakukan melalui metode *GAFIS* dikombinasikan dengan parameter hasil pembelajaran dari metode *OASIS* diharapkan akan memberikan hasil yang terbaik dan invarian terhadap domain penggambaran citra itu sendiri.

EKSPERIMEN

Eksperimen dilakukan dengan menggunakan data set public berikut:

- PascalVOC 2007 (Everingham, Van-Gool, Williams, Winn, & Zisserman), 10.000 citra yang berukuran 500x333 piksel. Data ini digunakan dalam eksperimen domain foto.
- Random Flickr Images (Shrivastava, Malisiewicz, Gupta, & Efros, 2011), 10.000 citra dengan ukuran 800x600 piksel. Data ini digunakan sebagai negative-samples atau natural-world dalam proses ekstraksi keunikan citra.

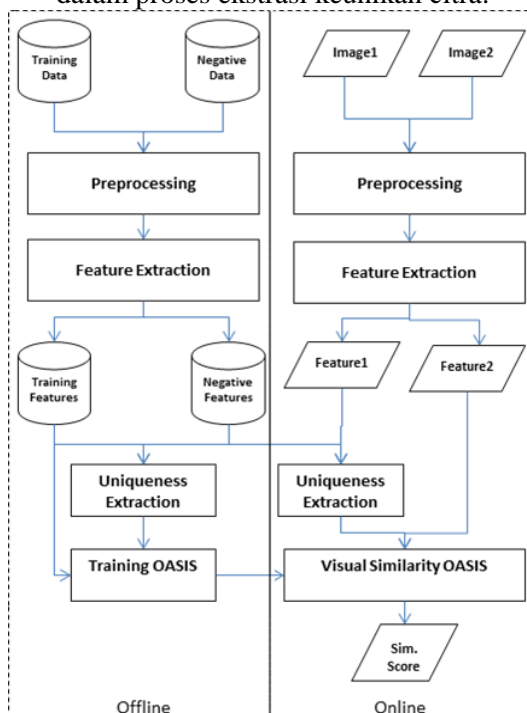


Figure 1. Skema metode Hybrid

- Painting Queries dan Sketch Queries (Shrivastava, Malisiewicz, Gupta, & Efros, 2011), yang digunakan sebagai data testing untuk eksperimen domain lukisan dan sketsa.

Sebelum dilakukan proses ekstraksi fitur, untuk lebih memudahkan dan mempercepat proses ekstraksi fitur, semua citra diubah ukurannya menjadi 6912 piksel. Proses ini dilakukan terhadap semua dataset citra baik itu kueri maupun retrieval set dan negative set dengan menggunakan toolbox image processing yang terdapat di aplikasi MATLAB.

Setelah dilakukan preprocessing, semua citra kemudian diekstraksi dengan menggunakan metode HoG, dan terakhir dilakukan pengukuran similarity antara citra kueri dan citra di dalam dataset. Pengukuran similarity dilakukan dengan menggunakan variasi tiga metode, yaitu *GAFIS*, *OASIS*, dan *Hybrid*. Tujuan dari pengukuran ini adalah untuk mendapatkan skor kemiripan antara citra kueri dan masing-masing citra yang terdapat di dalam dataset yang kemudian digunakan sebagai dasar perankingan. Kemiripan yang diukur dalam hal ini merupakan kemiripan global, mengingat citra yang terdapat di dalam koleksi sangat besar, sehingga dibutuhkan proses pengukuran yang cepat.

Dalam eksperimen digunakan MATLAB untuk mengimplementasikan masing-masing metode. Untuk implementasi metode *OASIS* digunakan script yang telah diimplementasikan sebelumnya pada (Chechik, Sharma, Shalit, & Bengio, 2009). Adapun untuk membangun model *GAFIS* digunakan data Random Flickr Images sebagai negative-set, sedangkan untuk membangun model *OASIS* digunakan data trainval dari dataset PascalVOC 2007. Untuk metode *Hybrid* sendiri

menggunakan kedua data tersebut dalam proses pembangunan modelnya.

Evaluasi terhadap kinerja sistem dilakukan melalui perankingan kemudian dihitung average-precision pada top-5, top-10, top-50, dan top-100 untuk masing-masing eksperimen.

Eksperimen pada Domain Foto

Dalam eksperimen ini digunakan sebanyak 4.952 buah citra test dari dataset PascalVOC 2007 yang terdiri dari dua puluh kelas. Adapun hasilnya yaitu sebagaimana tersaji dalam Tabel 1 dan dalam Figure 2.

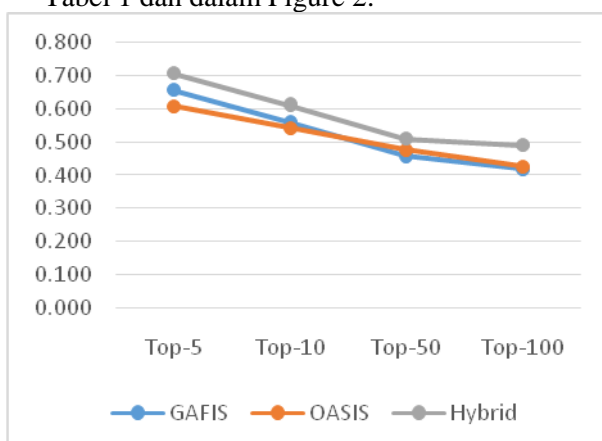


Figure 2. Grafik Precision Eksperimen Domain Foto

Berdasarkan grafik pada Figure 2, terlihat bahwa metode Hybrid mampu mengungguli GAFIS dan OASIS, dengan rata-rata presisi pada Top-5, Top-10, Top-50, dan Top-100 masing-masing secara berurutan yaitu 0.706, 0.612, 0.510, dan 0.491. Hal ini menunjukkan, bahwasannya proses tuning parameter metode Hybrid pada domain foto cukup berhasil.

Eksperimen pada Domain Lukisan

Pada eksperimen domain citra lukisan hanya digunakan sebanyak sebelas buah citra test dari kelas car. Hal ini dikarenakan keterbatasan data pasangan set kueri dan set retrieval untuk domain lukisan. Adapun hasilnya

yaitu sebagaimana tersaji dalam Tabel 2 dan Figure 3.

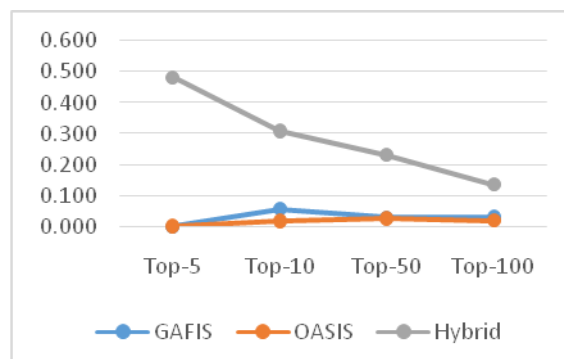


Figure 3. Grafik Precision Eksperimen Domain Lukisan

Hasil eksperimen pada domain lukisan menunjukkan tingkat presisi metode Hybrid yang lebih tinggi dibandingkan kedua metode lainnya. Bahkan disaat metode GAFIS dan OASIS gagal mendapatkan citra yang sesuai pada Top-5, metode Hybrid berhasil memperolehnya pada beberapa percobaan, sehingga memberikan rata-rata presisi yang cukup baik. Adapun rata-rata tingkat presisi metode Hybrid pada Top-5, Top-10, Top-50, dan Top-100 masing-masing secara berurutan yaitu 0.482, 0.309, 0.231, dan 0.136.

Eksperimen pada Domain Sketsa

Pada domain sketsa, eksperimen dilakukan dengan menggunakan sebanyak 38 buah citra test dari dataset Data Driven Visual Similarity yang terdiri dari dua kelas. Adapun hasilnya yaitu sebagaimana tersaji dalam tabel 3 dan dalam Figure 4.




Figure 4. Grafik Precision Eksperimen Domain Sketsa

Domain sketsa memiliki tingkat kesulitan yang tinggi, mengingat konten dari kueri terkadang tidak mencerminkan seluruh bagian yang ingin dicari. Hasil eksperimen pun menunjukkan hasil presisi yang cukup rendah. Meskipun demikian, metode Hybrid masih tetap mampu mengungguli GAFIS dan OASIS, dengan hasil presisi pada Top-5, Top-10, Top-50, dan Top-100 secara berurutan yaitu 0.050, 0.104, 0.204, dan 0.164.

KESIMPULAN

Metode Hybrid yang merupakan gabungan dari metode *Gaussian Approximation for Fast Image Similarity* dan metode *Online Algorithm for Large Scale Image Similarity* memberikan performa yang stabil pada *cross-domain image retrieval*. Hal ini dikarenakan metode ini mampu melakukan ekstraksi keunikan terhadap citra kueri melalui pembobotan yang dilakukan dengan memanfaatkan parameter Gaussian dari citra *negative-set* yang dikombinasikan dengan *parameter tuning* terhadap bobot tersebut melalui pembelajaran berdasarkan algoritma OASIS.

REFERENSI

- Atta, R., Joshi, D. D., Li, J., & Wang, J. Z. (2008). Image Retrieval: Ideas, Influences, and Trends of the New Age. *ACM Transactions on Computing Surveys*.
- Bar-Hillel, A., Hertz, T., Shental, N., & Weinshall, D. (2003). Learning Distance Functions using Equivalence Relations. *Proc. of 20th International Conference on Machine Learning (ICML)*, (pp. 11–18).
- Bay, H., Tuytelaars, T., & Gool, L. V. (2008, June). Speeded-Up Robust Features (SURF). *Computer Vision and Image Understanding*, 110(3), 346-359 .
- Chechik, G., Sharma, V., Shalit, U., & Bengio, S. (2009). An Online Algorithm for Large Scale Image Similarity Learning. *Advances in Neural Information Processing Systems*.
- Dalal, N., & Triggs, B. (2005). Histograms of Oriented Gradients for Human Detection. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, (pp. 886 - 893). San Diego.
- Everingham, M., Van-Gool, L., Williams, C. K., Winn, J., & Zisserman, A. (n.d.). *The PASCAL Visual Object Classes Challenge 2007 (VOC2007) Results*. Retrieved from <http://www.pascal-network.org/challenges/VOC/voc2007/workshop/index.html>
- Gharbi, M., Malisiewicz, T., Paris, S., & Durand, F. (2012). *A Gaussian Approximation of Feature Space for Fast Image Similarity*. Massachusetts: DSpace@MIT.
- Lowe, D. G. (2004). Distinctive Image Features from Scale-Invariant Keypoints. *International Journal of Computer Vision*, 60(2), 91-110.
- Shrivastava, A., Malisiewicz, T., Gupta, A., & Efros, A. A. (2011). Data-driven visual similarity for cross-domain image matching. *Proceedings of the 2011 SIGGRAPH Asia Conference*. Hong Kong.
- Weinberger, K., Blitzer, J., & Saul, L. (2006). Distance metric learning for large margin nearest neighbor classification. *NIPS*, 18.
- Wol, L., Hassner, T., & Taigman, Y. (2009). The One-Shot similarity kernel . *IEEE International Conference on Computer Vision 12th*, (pp. 897 - 902). Kyoto.
- Xing, E., Ng, A., Jordan, M., & Russell, S. (2003). Distance metric learning

with application to clustering with
side information. *NIPS*, 15, 521–
528.

APPENDIX
Tabel 1. Hasil Eksperimen pada Domain Foto

Class Data	Precision @Top-5			Precision @Top-10			Precision @Top-50			Precision @Top-100		
	GAFIS	OASIS	Hybrid	GAFIS	OASIS	Hybrid	GAFIS	OASIS	Hybrid	GAFIS	OASIS	Hybrid
aeroplane	0.897	0.830	0.950	0.818	0.764	0.868	0.617	0.602	0.665	0.518	0.507	0.589
dog	0.620	0.565	0.672	0.523	0.506	0.578	0.443	0.461	0.493	0.410	0.417	0.481
bicycle	0.724	0.671	0.771	0.629	0.616	0.686	0.459	0.479	0.507	0.402	0.408	0.471
horse	0.569	0.504	0.611	0.473	0.436	0.521	0.385	0.388	0.437	0.355	0.347	0.425
bird	0.622	0.594	0.671	0.528	0.528	0.575	0.444	0.463	0.493	0.410	0.416	0.479
motorbike	0.564	0.514	0.621	0.473	0.444	0.521	0.388	0.400	0.436	0.356	0.358	0.425
boat	0.607	0.600	0.659	0.506	0.519	0.562	0.416	0.443	0.466	0.379	0.391	0.450
person	0.829	0.773	0.875	0.736	0.738	0.788	0.640	0.710	0.690	0.601	0.663	0.668
bottle	0.594	0.616	0.651	0.493	0.514	0.544	0.405	0.435	0.452	0.371	0.386	0.441
pottedplant	0.572	0.519	0.619	0.472	0.452	0.523	0.390	0.409	0.443	0.363	0.371	0.434
bus	0.644	0.572	0.696	0.528	0.510	0.584	0.424	0.442	0.476	0.386	0.395	0.459
sheep	0.564	0.523	0.610	0.468	0.452	0.517	0.391	0.405	0.444	0.363	0.364	0.434
car	0.828	0.803	0.872	0.735	0.751	0.785	0.609	0.658	0.657	0.556	0.592	0.627
sofa	0.620	0.551	0.673	0.530	0.490	0.576	0.443	0.443	0.492	0.409	0.401	0.480
cat	0.674	0.591	0.713	0.571	0.534	0.616	0.475	0.485	0.526	0.439	0.440	0.509
train	0.692	0.644	0.738	0.583	0.578	0.640	0.471	0.492	0.522	0.429	0.438	0.501
chair	0.631	0.568	0.685	0.541	0.505	0.592	0.461	0.469	0.510	0.428	0.431	0.501
tvmonitor	0.663	0.632	0.712	0.568	0.561	0.624	0.476	0.503	0.528	0.436	0.455	0.509
cow	0.580	0.521	0.630	0.481	0.454	0.537	0.403	0.403	0.454	0.371	0.363	0.442
diningtable	0.648	0.581	0.696	0.548	0.520	0.602	0.457	0.464	0.509	0.426	0.418	0.498
Rataan	0.657	0.609	0.706	0.560	0.544	0.612	0.460	0.478	0.510	0.420	0.428	0.491

Tabel 2. Hasil Eksperimen pada Domain Lukisan

Class Data	Precision @Top-5			Precision @Top-10			Precision @Top-50			Precision @Top-100		
	GAFIS	OASIS	Hybrid	GAFIS	OASIS	Hybrid	GAFIS	OASIS	Hybrid	GAFIS	OASIS	Hybrid
car	0.000	0.000	0.482	0.056	0.018	0.309	0.029	0.026	0.231	0.030	0.019	0.136

Tabel 3. Hasil Eksperimen pada Domain Sketsa

Class Data	Precision @Top-5			Precision @Top-10			Precision @Top-50			Precision @Top-100		
	GAFIS	OASIS	Hybrid	GAFIS	OASIS	Hybrid	GAFIS	OASIS	Hybrid	GAFIS	OASIS	Hybrid
bicycle	0.000	0.000	0.045	0.045	0.000	0.044	0.066	0.005	0.165	0.055	0.008	0.135
car	0.000	0.000	0.055	0.033	0.011	0.163	0.046	0.042	0.242	0.045	0.047	0.192
Rataan	0.000	0.000	0.050	0.039	0.006	0.104	0.056	0.024	0.204	0.050	0.028	0.164
