

Struktur pohon diatas menggambarkan dependensi mutual antara fitur-fitur. Tidak ada model dependensi untuk sample non-mata dikarenakan kekurangan struktur statistik. Sangatlah beralasan untuk menggunakan pohon dependensi yang sama untuk sample-sample negatif. Bila dilakukan, mencocokkan sample negatif kedalam model menunjukkan deviasi dari pola sample positif.

## 2.1. Menemukan subset dengan dependensi terkecil

Setiap golongan objek memiliki beberapa kesamaan struktur. Informasi tentang struktur membatasi dependensi antara fitur-fitur. Fitur dari substruktur berbeda diasumsikan kurang dependen. Informasi mutual adalah sebuah metrik untuk mengavaluasi dependensi mutual antara fitur-fitur. Informasi mutual didefinisikan dengan syarat entropi :

$$I(\mathbf{X}_1, \mathbf{X}_2) = H(\mathbf{X}_1) + H(\mathbf{X}_2) - H(\mathbf{X}_1, \mathbf{X}_2); \quad (1)$$

dimana  $H(\mathbf{X}_1)$  adalah entropi dari variable random  $X_i$ ,  $i = 1, 2$ , dan  $H(\mathbf{X}_1, \mathbf{X}_2)$  adalah entropi gabungan. Mereka didefinisikan sebagai berikut :

$$H(\mathbf{X}_i) = - \sum P(\mathbf{X}_i) \log P(\mathbf{X}_i); \quad (2)$$

$$H(\mathbf{X}_1, \mathbf{X}_2) = - \sum \sum P(\mathbf{X}_1, \mathbf{X}_2) \log P(\mathbf{X}_1, \mathbf{X}_2). \quad (3)$$

Informasi mutual sebenarnya adalah divergensi KL antara fungsi massa probabilitas gabungan  $P(\mathbf{X}_1, \mathbf{X}_2)$  dengan produk dari fungsi massa probabilitas marjinal  $P(\mathbf{X}_1)$  dan  $P(\mathbf{X}_2)$  :

$$I(\mathbf{X}_1, \mathbf{X}_2) = \sum_{\mathbf{X}_1} \sum_{\mathbf{X}_2} P(\mathbf{X}_1, \mathbf{X}_2) \log \frac{P(\mathbf{X}_1, \mathbf{X}_2)}{P(\mathbf{X}_1)P(\mathbf{X}_2)}. \quad (4)$$

Definisi tersebut menunjukkan bahwa informasi mutual mengukur jumlah informasi yang dipegang oleh sebuah variable random tentang yang lainnya, atau dependensi mutual. Nilai maksimalnya akan dicapai bila ada pemetaan bijektif antar nilai  $X_1$  dengan  $X_2$ . Di titik ekstrim lainnya,  $I(\mathbf{X}_1, \mathbf{X}_2)$  menuju nol bila  $X_1$  dan  $X_2$  independen secara statistik. Dikarenakan hal ini, skema *pengelompokan* yang diadaptasi dari algoritma *pengelompokan K-means* tradisional dipakai. Dalam pengukuran jarak, digunakan fungsi pengurangan pasangan informasi mutual, lebih spesifiknya perbandingan terbalik dari informasi mutual. Bagaimanapun, *K-means* menggunakan sentroid dari *kelompok* untuk memperbaharui. Dikarenakan informasi mutual hanya terdefinisi pada bidang  $X_s$ , sentroid poin-poinnya menjadi tidak berarti. Jadi untuk setiap kelompok  $X_i$ , kita menggunakan fitur dengan jarak rata-rata terkecil. Karena property konvergen dari *K-means* hanya menangani atribut numeric, diperlukan pengubahan acuan pemberhentian untuk memastikan konvergensi. Prosedur pengelompokan akan berhenti bila tidak ada poin yang merubah label kelompok. Metode

pengelompokan ini dapat menjamin bahwa pertengahan informasi mutual perpasangan antara subset-subset meningkat. Seperti di pengelompokan *K-means*, jumlah kelompok harus disediakan sebelumnya. Jumlah kelompok ditentukan dengan menaikkan jumlahnya sampai informasi mutual perpasangan terendah antar subset yang berbeda mencapai batas  $\delta$  secara iteratif. Prosedur pengelompokan diatas dapat diringkas menjadi sebagai berikut :

1. Estimasi informasi mutual dari setiap pasang fitur di  $\{X_s\}$  oleh distribusi empirik, dengan menggunakan persamaan (4). Hitung perbandingan terbalik dari informasi mutual sebagai jarak antar titik :

$$D(\mathbf{X}_i, \mathbf{X}_j) = \frac{1}{I(\mathbf{X}_i, \mathbf{X}_j)}; \quad (5)$$

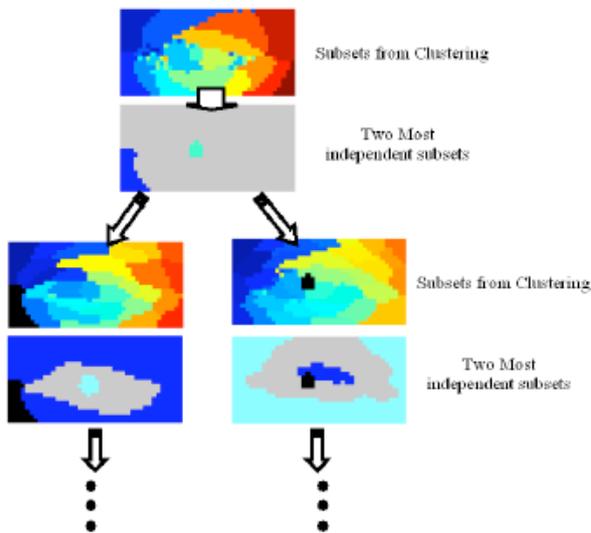
2. Untuk  $c=3, \dots, K$ , lakukan pengelompokan dengan langkah sebagai berikut :
  - a. Pilih secara acak titik  $c$   $X_s^c$  dari  $\{X_s\}$  sebagai bibit untuk kelompok  $c$ .
  - b. Inisiasi kesalahan  $\epsilon$  dengan bilangan yang besar.
  - c. Selama  $\epsilon > 0$  :
    - i. Tentukan tiap poin  $X_l$  pada kelompok yang berkorespondensi berdasarkan patokan tetangga terdekat, dengan menggunakan  $D(\mathbf{X}_i, \mathbf{X}_s^c)$  :
$$\nu_i = \arg \min_c D(\mathbf{X}_i, \mathbf{X}_s^c); \quad (6)$$
    - ii. Hitung jumlah poin yang berganti label.
    - iii. Untuk tiap kelompok, cari poin dengan jarak rata-rata minimal dengan semua sisa poin di kelompok yang sama.
  - d. Hitung rata-rata informasi mutual perpasangan antar kelompok.
  - e. Cari kelompok dengan rata-rata informasi mutual perpasangan antar kelompok yang minimal,  $\min I_{c_1, c_2}$ ;
3. Jika  $\min I_{c_1, c_2} < \delta$ , stop;
4. Jika  $c = K$  dan  $\min I_{c_1, c_2} < \delta$ , subsetnya cukup padat, yang mengartikan bahwa ini adalah sebuah node daun.

Prosedur ini memberikan kita sebuah partisi dari kelompok fitur berdasarkan informasi mutual perpasangannya. Jika subset-subset yang rata-rata informasi mutual perpasangan antara mereka cukup rendah, kedua subset tersebut dapat dianggap sebagai independen kondisional. Untuk tujuan ini, rata-rata

informasi mutual perpasangan antara tiap dua subset diperiksa. Anggap untuk subset  $X_{S_1}$ , ada subset  $X_{S_m}$  yang memenuhi :

$$\frac{1}{|\mathcal{X}_{S_1}| |\mathcal{X}_{S_m}|} \sum_{X_i \in \mathcal{X}_{S_1}} \sum_{Y_j \in \mathcal{X}_{S_m}} I(X_i, Y_j) < \delta, \quad m = 2, \dots, M; \quad (7)$$

maka  $A = X_{S_1}$  dan  $B = \cup_{m=2}^M X_{S_m}$  adalah dua subset paling sedikit independen yang dipilih. Seperti yang pernah diperkenalkan sebelumnya, gabungan dari semua subset lain,  $C = \cup_{m \neq 1, \dots, M} X_{S_m}$  disimpan sebagai *current node*. Gabungannya dengan dua subset independen kondisional, A dan B secara individual diberikan ke subpohon. Gambar 2 menunjukkan hasil dari dekomposisi struktur pohon pada dua tingkat pertama.



Gambar 2: Ilustrasi dekomposisi struktur pohon.

### 3. EVALUASI EKSPERIMENTAL

Di bagian ini, akan dibahas kinerja algoritma ini. Dalam implementasinya, agar detektor mata yang dibangun memiliki ketepatan tinggi dalam semua kondisi, *image space* yang orisinal digunakan, dan fitur dalam implementasinya adalah intensitas pixel dalam gambar.

#### 3.1. Evaluasi Kinerja pada Gambar Wajah

Evaluasi ini adalah pemeriksaan kemampuan dari implementasi algoritma dalam membedakan mata dari bagian wajah yang lainnya. Hasil eksperimennya menunjukkan bahwa detektor mata yang dibangun dari algoritma tersebut dapat mencapai keberhasilan deteksi sebesar 92.43%, dan kegagalan sebesar 7, 26%. Eksperimen juga menunjukkan bahwa implementasi algoritma pohon biner ini mampu memberikan hasil akurat, yaitu dengan 84,64% dari keberhasilan deteksi memberikan hasil deteksi tepat

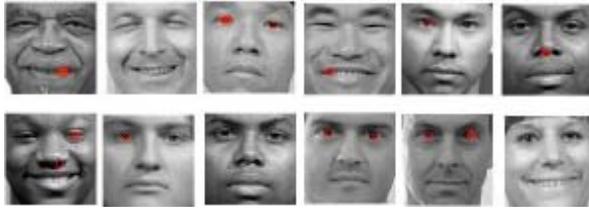
ditengah bagian pupil. Gambar 3 menunjukkan contoh-contoh hasil eksperimen implementasi algoritma pohon biner dengan keakuratan tinggi (hasil deteksi tepat ditengah bagian pupil). Sedangkan gambar 4 menunjukkan contoh-contoh hasil eksperimen implementasi algoritma pohon biner dengan keakuratan lebih rendah (hasil deteksi tidak tepat ditengah bagian pupil). Gambar 5 menunjukkan hasil eksperimen implementasi algoritma pohon biner yang gagal mendeteksi mata. Yang menarik adalah algoritma ini bahkan mampu membedakan mata kiri dengan mata kanan. Hasil deteksi menunjukkan bahwa mata kanan hanya dideteksi sebanyak 5,99% dari jumlah eksperimen yang dilakukan, dan menunjukkan bahwa hampir semua eksperimen yang dilakukan menghasilkan deteksi mata kiri, dan secara langsung dapat membedakan kedua mata.



Gambar 3 : Hasil eksperimen implementasi algoritma pohon biner dengan keakuratan tinggi (Deteksi tepat ditengah bagian pupil).



Gambar 4 : Hasil eksperimen implementasi algoritma pohon biner dengan keakuratan lebih rendah (Deteksi tidak tepat ditengah bagian pupil).



Gambar 5 : Hasil eksperimen implementasi algoritma pohon biner yang gagal mendeteksi mata.

### 3.2. Evaluasi pada Latar Belakang Kompleks

Eksperimen juga dilakukan pada lingkungan yang akan memberikan latar belakang kompleks pada gambar yang diambil. Setiap gambar yang diambil hanya berisi satu orang. Bagian foto yang diambil hanya yang memiliki tekstur yang cukup, dan evaluasi tekstur dilakukan dengan menggunakan filter Laplacian. Hasil yang didapat dari evaluasi gambar berlatar belakang kompleks ini cukup baik. Gambar 6 menunjukkan hasil eksperimen pada latar belakang kompleks yang berhasil mendeteksi mata, sedangkan gambar 7 menunjukkan hasil eksperimen pada latar belakang kompleks yang gagal mendeteksi mata.



Gambar 6 : Hasil eksperimen implementasi algoritma pohon biner pada gambar berlatar belakang kompleks yang berhasil mendeteksi mata.



Gambar 7 : Hasil eksperimen implementasi algoritma pohon biner pada gambar berlatar belakang kompleks yang gagal mendeteksi mata.



### 3.3. Evaluasi pada Pengendara Mobil

Eksperimen juga dilakukan langsung pada skenario pengendara mobil, dengan memasang kamera video di *dashboard* mobil dan mengarah pada wajah pengendara dari sisi kanan. Hasil eksperimen diambil dari beberapa frame. Hasil yang didapat adalah banyaknya kesalahan deteksi, walaupun mata kanan juga berhasil dideteksi. Hal ini terjadi karena beberapa faktor, seperti gambar yang diambil bersifat *noisy*, dan juga bergantung pada pose kepala pengendaranya. Gambar 8 menunjukkan hasil eksperimen pada pengendara mobil.



Gambar 8 : Hasil eksperimen implementasi algoritma pohon biner pada skenario pengendara mobil. Terjadi banyak kesalahan deteksi.

#### 4. KESIMPULAN

Pohon biner dapat digunakan dalam pemodelan struktur statistik dari mata manusia. Pada tiap tingkat, fitur dikelompokkan menjadi subset-subset berdasarkan informasi mutual perpasangannya, dan subpohon dibangun dengan mengesampingkan subset-subset paling independen secara berturut-turut. Prosedur ini diulangi sampai semua fitur didalam node daun memiliki informasi mutual yang cukup tinggi. Hal yang dijadikan fitur adalah intensitas piksel dalam gambar. Detektor mata hasil dari implementasi algoritma pohon biner ini lalu diaplikasikan pada gambar wajah dan gambar dengan latar belakang kompleks, dengan hasil eksperimennya memberikan tingkat keberhasilan deteksi yang tinggi dan tingkat kegagalan yang rendah. Pada eksperimen gambar wajah, tingkat keberhasilan deteksi mata adalah 92,43%, dan tingkat kegagalannya adalah 7,26%. Hasil eksperimen ini juga menunjukkan bahwa detektor mata hasil implementasi algoritma pohon biner tersebut dapat membedakan mata kanan dengan mata kiri, dan dapat menghasilkan deteksi mata dengan akurasi yang tinggi. Pada eksperimen gambar berlatar belakang kompleks, digunakan filter Laplacian untuk menentukan tekstur yang cukup, dan hasil yang didapat cukup baik. Pada eksperimen yang dilakukan pada skenario pengendara mobil, hasilnya menunjukkan potensi detektor tersebut untuk diaplikasikan pada kendaraan pintar, yang diharapkan dapat mendeteksi kelelahan pengendara untuk mencegah kecelakaan lalu lintas. Aplikasi detektor mata ini juga diharapkan dapat dikembangkan untuk mendeteksi keadaan seseorang dari matanya, seperti kesehatan dan identitas. Untuk saat ini, biaya komputasi dari prosedur tersebut masih tergolong tinggi, sehingga diharapkan ada prosedur yang memiliki biaya komputasi rendah dan kecepatan deteksi yang tinggi.

#### DAFTAR REFERENSI

- [1] Munir, Rinaldi. (2006). *Diktat Kuliah IF2153 Matematika Diskrit*. Program Studi Teknik Informatika, Institut Teknologi Bandung.
- [2] T. D. Rikert, M. J. Jones and P. Viola, *A Cluster-Based Statistical Model for Object Detection*, Proceedings of the International Conference on Computer Vision-Volume 2 - Volume 2 Page: 1046 Year of Publication: 1999
- [3] H. Schneiderman and T. Kanade, *Object Detection Using the Statistics of Parts*, International Journal of Computer Vision archive Volume 56 , Issue 3, pp. 151 - 177, February-March 2004.
- [4] K. Nguyen et. al., *Differences in the Infrared Bright Pupil Response of Human Eyes*, Proc. ETRA 2002 - Eye Tracking Research and Applications Symposium. New York, ACM. 2002, p. 133-56, March 2002.
- [5] H. Schneiderman, *Learning a Restricted Bayesian Network for Object Detection*, IEEE Conference on Computer Vision and Pattern Recognition, IEEE, June 2004.
- [6] X. Liu, F. Xu and K. Fujimura. *Real-Time Eye Detection and Tracking for Driver Observation Under Various Light Conditions*, IEEE Intelligent Vehicle Symposium, Versailles, France, June 18-20, 2002.