

Pendekatan Gabungan Analisis Komponen Utama dan Analisis Diskriminan Linear (AKU-ADL) untuk Pengelasan Kedudukan Penumpang

Liong Choong-Yeun dan Tee Pei-Gim

Pusat Pengajian Sains Matematik, Fakulti Sains dan Teknologi

Universiti Kebangsaan Malaysia

43600 UKM Bangi, Selangor, Malaysia

E-mel: lg@ukm.my

ABSTRAK

Dalam makalah ini dibincangkan kajian untuk menilai keberkesanan kaedah gabungan analisis komponen utama dan analisis diskriminan linear (AKU-ADL) untuk pengelasan kedudukan penumpang. Sebanyak sepuluh kelas kedudukan yang dikenali sebagai kelas "floor", "hand", "dash board", "lean", "turn right", "turn left", "standard", "radio", "back right" dan "back left" telah dikaji. Kelas-kelas kedudukan itu adalah mengikut takrifan pakar daripada PSA Peugeot Citroen di Perancis. Imej-imej penumpang disegmentasi menggunakan teknik pengambangan setempat yang dibangunkan dalam bahasa C++. Seterusnya 36 fitur momen ortogon Legendre (MOL) dijana daripada imej tersebut yang membentuk fitur-fitur untuk mengelaskan kedudukan penumpang berkenaan. Analisis komponen utama dijalankan untuk menurunkan dimensi fitur kepada satu set dimensi yang lebih rendah. Dalam langkah ujian kecukupan pensampelan, bilangan fitur telah dikurangkan kepada 24 kerana terdapat 12 fitur yang tidak memenuhi syarat. Seterusnya, analisis komponen utama ke atas 24 fitur tersebut telah berupaya menurunkannya kepada cuma 5 fitur utama sahaja, iaitu kepada 5 komponen utama. Dengan menggunakan lima skor komponen ini, analisis diskriminan linear telah dilaksanakan untuk mengelaskan imej-imej kedudukan penumpang tersebut. Hasil analisis diskriminan linear menggunakan SPSS menunjukkan tahap pengelasan adalah keseluruhannya sempurna, iaitu 100%, baik menggunakan pengelasan data asal, mahupun pengelasan secara pengelasan silang. Oleh itu, boleh disimpulkan bahawa analisis komponen utama telah berjaya menurunkan data ini kepada komponen-komponen utama yang dapat mengelaskan kedudukan penumpang tersebut dengan sangat sempurna. Hasil pengelasan yang 100% membuktikan keberkesanan dan kecekapan penggunaan kaedah AKU-ADL untuk pengelasan kedudukan penumpang yang dikaji. Hasil pengelasan ini adalah lebih baik daripada kajian menggunakan ADL sahaja yang berasaskan 9 fitur MOL yang signifikan dengan hasil pengelasan setinggi 99.5% bagi kaedah pengelasan biasa, dan 99.1% bagi kaedah pengelasan pengelasan silang, masing-masingnya.

Kata kunci: analisis komponen utama (AKU); analisis diskriminan linear (ADL); AKU-ADL; pengelasan kedudukan penumpang.

PENGENALAN

Satu penyelidikan yang menarik dan mendapat perhatian dalam industri automotif adalah penyelidikan ke arah penghasilan kereta pintar (Boverie, 2002; Gottschalk, 1997; Hardin, 2002; Liong, 2001). Terdapat pelbagai aspek dan teknologi yang diselidiki seperti aspek penggunaan sensor pintar untuk "memahami" persekitaran dan aksesori kenderaan, teknologi radar untuk mengelakkan pelanggaran, teknologi infra-merah untuk sistem visyen waktu malam dan sistem pengecaman kedudukan penumpang (Boverie, 2002; Destéfanis *et al.*, 2000; Hardin, 2002; Insurance Institute for Highway Safety, 1988; Liong, 2001). Dalam makalah ini, aspek yang dibincangkan adalah berkenaan dengan sistem pengecaman kedudukan penumpang menggunakan sistem visyen. Motivasi utama ke arah penggunaan sistem visyen adalah di atas kesedaran akan kehebatan dan kelebihan daya penglihatan manusia berbanding dengan deria-deria lain (Brown, 1988; Davies, 1997; Levine, 1985). Suatu sistem berasaskan penglihatan memastikan kesemua maklumat kedudukan yang ada pada satu-satu ketika sentiasa tersimpan, dan hanya kemampuan pemprosesan sahaja yang membataskan maklumat yang dapat dicerap untuk membuat keputusan. Malah, menurut pakar daripada PSA Peugeot Citroen, hanya kuasa pemprosesan dan kecanggihan algoritma sahaja yang membataskan kemampuan sistem sedemikian berbanding dengan sistem-sistem yang berasaskan sensor dan isyarat sahaja (Liong, 2001). Sistem visyen juga boleh membentuk suatu sistem penyimpanan maklumat yang berguna untuk penyelidikan masa akan datang.

Aspek pengecaman kedudukan penumpang telah menarik perhatian dalam penyelidikan melibatkan penggunaan perkakasan seperti sensor, dan aspek perisian atau pendekatan lembut menggunakan pemprosesan imej (Boverie, 2002; Destéfanis *et al.*, 2000). Penulis berpendapat gabungan kedua-dua teknologi tentu sahaja akan menghasilkan sistem hibrid yang lebih besar manfaatnya kepada pengguna. Di antara kepentingan mengetahui kedudukan penumpang adalah dalam pelepasan beg udara keselamatan. Kajian telah menunjukkan kedudukan relatif penumpang kepada beg udara keselamatan boleh mengakibatkan kematian atau pelbagai jenis kecederaan apabila beg udara itu dilepaskan (Grisoni *et al.*, 2000; Insurance Institute for Highway Safety, 1988; Yaremchuk dan Dobie, 2001).

Imej boleh ditakrifkan sebagai suatu fungsi dua dimensi, $f(x,y)$, dengan x dan y adalah koordinat ruang, dan amplitud f pada sebarang pasangan koordinat (x,y) dipanggil intensiti atau paras kelabu imej itu pada titik tersebut. Apabila x , y dan nilai amplitud bagi f semuanya terhingga dan

diskret, imej itu dinamakan sebagai imej digital (Gonzalez dan Woods, 2002).

Membahagikan objek dalam imej kepada kelas tertentu adalah sebahagian dari pengecaman pola (Jähne, 2002; Webb, 2002). Suatu kelas pola pula ialah suatu golongan pola yang mempunyai sifat-sifat yang sama (Gonzalez dan Woods, 2002). Jadi, pengecaman pola boleh ditakrifkan sebagai proses membahagikan pola-pola kepada kelas yang tertentu mengikut sifat-sifat tertentu.

Langkah-langkah yang perlu diambil dalam menyelesaikan suatu masalah pengecaman pola meliputi: (i) perumusan masalah, (ii) pengutipan data, (iii) pemeriksaan data awal, (iv) pemilihan atau penurunan fitur, (v) pengelasan, sama ada dengan penyeliaan atau tanpa penyeliaan, dan (vi) tafsiran keputusan (Webb, 2002). Dalam makalah ini, tumpuan diberikan kepada penurunan fitur dan pengelasan dengan penyeliaan. Penurunan fitur dijalankan dengan analisis komponen utama (AKU) manakala pengelasan dengan penyeliaan dilaksanakan dengan analisis diskriminan linear (ADL). Kaedah ini dikenali sebagai kaedah gabungan analisis komponen utama dan analisis diskriminan linear (AKU-ADL). Analisis berkenaan dijalankan dengan menggunakan pakej SPSS.

Seksyen berikutnya menyajikan sorotan kesusasteraan tentang kaedah AKU dan ADL, serta penggunaan kaedah gabungan AKU-ADL. Seterusnya seksyen 3 mengulas tentang imej kedudukan penumpang, kaedah segmentasi, fitur momen yang diguna, dan penganalisan menggunakan AKU dan ADL dalam SPSS. Kaedah pengelasan data asal dan pengesahan silang turut diterangkan. Seksyen 4 menerangkan keputusan uji kaji dan analisis, dan akhir sekali seksyen 5 memberikan kesimpulan kajian dan cadangan untuk kajian selanjutnya.

SOROTAN KESUSASTERAAN

ADL ialah suatu kaedah yang berguna dalam pengecaman pola (Zhuang dan Dai, 2007). ADL melibatkan proses memperoleh suatu variat, iaitu gabungan linear dua atau lebih pembolehubah tidak bersandar, yang akan membezakan kelas-kelas yang telah ditakrifkan terlebih dahulu dengan baik. Ini boleh dilakukan dengan menetapkan pemberat variat-variati itu untuk memaksimumkan varians antara kelas relatif kepada varians di dalam kelas. Gabungan linear bagi suatu ADL yang dikenali

sebagai fungsi diskriminan diperoleh daripada suatu persamaan yang berbentuk (Field, 2005; Hair *et al.*, 1979):

$$Z_{jk} = a + W_i X_{ik} + W_2 X_{2k} + \dots + W_n X_{nk} \quad [1]$$

dengan

Z_{jk} = skor diskriminan Z bagi fungsi diskriminan j untuk objek k

a = pintasan

W_i = pemberat diskriminan untuk pembolehubah tidak bersandar i

X_{ik} = pembolehubah tidak bersandar i untuk objek k .

ADL berguna apabila seseorang berminat untuk memahami perbezaan kelas atau mengklasifikasikan objek kepada kelas yang betul. Ini berpadanan dengan objektif kajian ini, dan oleh yang demikian, ADL adalah suatu kaedah yang sesuai digunakan untuk kajian ini.

AKU diperkenalkan oleh Pearson (1901), dan merupakan suatu teknik penurunan dimensi yang popular (Belhumeur *et al.*, 1997; Park *et al.*, 2006; Yang dan Yang, 2003; Zhuang dan Dai, 2007). AKU adalah suatu proses ke arah menghasilkan pembolehubah baru (dalam tertib kepentingan menurun) yang merupakan suatu gabungan linear daripada pembolehubah-pembolehubah asal yang tidak berkorelasi antara satu sama lain. Salah satu sebab melakukan AKU adalah untuk mengurangkan data, iaitu mencari suatu kumpulan pembolehubah asas yang lebih kecil ke arah menerangkan data. Secara matematikanya, komponen utama y_1, y_2, \dots, y_q ditakrifkan sebagai gabungan linear pembolehubah asal x_1, x_2, \dots, x_q yang tidak berkorelasi seperti berikut:

$$y_1 = a_{11}x_1 + a_{12}x_2 + \dots + a_{1q}x_q$$

$$y_2 = a_{21}x_1 + a_{22}x_2 + \dots + a_{2q}x_q$$

⋮

$$y_q = a_{q1}x_1 + a_{q2}x_2 + \dots + a_{qq}x_q$$

dengan pekali a_{ij} ($i, j = 1, \dots, q$) dipilih sedemikian supaya syarat wajib, iaitu syarat varians maksimum dan tidak berkorelasi dipenuhi. Jumlah kuasa dua a_{ij} adalah satu supaya jumlah varians semua komponen sama dengan jumlah varians semua cerapan (Landau dan Everitt, 2003).

AKU sentiasa berguna sebagai langkah permulaan untuk analisis seterusnya disebabkan oleh potensinya dalam menurun dan menerangkan data. Misalnya, komponen utama mungkin menjadi input untuk analisis regresi, analisis kelompok atau analisis diskriminan (Deluzio dan Astephen, 2007; Johnson dan Wichern, 2002). Contoh hasil penyelidikan dengan menggunakan AKU adalah daripada Deluzio dan Astephen (2007). Dalam penyelidikan mereka, AKU diguna sebagai alat penurunan data dan juga sebagai langkah permulaan bagi analisis seterusnya untuk menentukan perbezaan gaya berjalan antara kumpulan pesakit osteoarthritis dan kumpulan kawalan. AKU berjaya menurunkan data-data ini dan memilih komponen utama yang dapat mendiskriminasi gaya berjalan dua kumpulan dengan baik, iaitu dengan tahap pengelasan 92%.

ADL yang melibatkan masalah berdimensi tinggi dan saiz sampel kecil sentiasa menghadapi masalah matriks kovarians singular dan kesukaran pengiraan vektor imej berdimensi tinggi. Kaedah AKU-ADL diguna untuk mengelakkan kesulitan ini. Dalam kaedah AKU-ADL ini, AKU digunakan terlebih dahulu untuk menurunkan dimensi data sebelum analisis diskriminan dijalankan. Kaedah ini digunakan dengan jayanya oleh Park *et al.* (2006), manakala dalam kajian Belhumeur *et al.* (1997), Yang dan Yang (2003), serta Zhuang dan Dai (2007), mereka mendapati bahawa kaedah AKU-ADL tidak menjamin kejayaan dalam pengecaman muka. Oleh itu, mereka telah mencadangkan beberapa pembaikan seperti menyingkirkan tiga komponen utama yang paling signifikan untuk mengurangkan varians yang disebabkan oleh pencahayaan (Belhumeur *et al.* 1997), menggunakan semua komponen utama yang positif (Yang dan Yang, 2003), serta mengguna kriteria diskriminan Fisher songsangan dan menambah suatu kekangan dalam prosedur AKU (Zhuang dan Dai, 2007). Bagaimanapun dalam kajian ini, pendekatan seumpaman Park *et al.* (2006) adalah memadai dan telah digunakan.

DATA DAN METODOLOGI KAJIAN

Objektif kajian ialah untuk menilai keupayaan AKU dalam menurunkan fitur data kedudukan penumpang dan mengelaskan imej-imej kedudukan penumpang di dalam kereta kepada kelas-kelas yang sepatutnya.

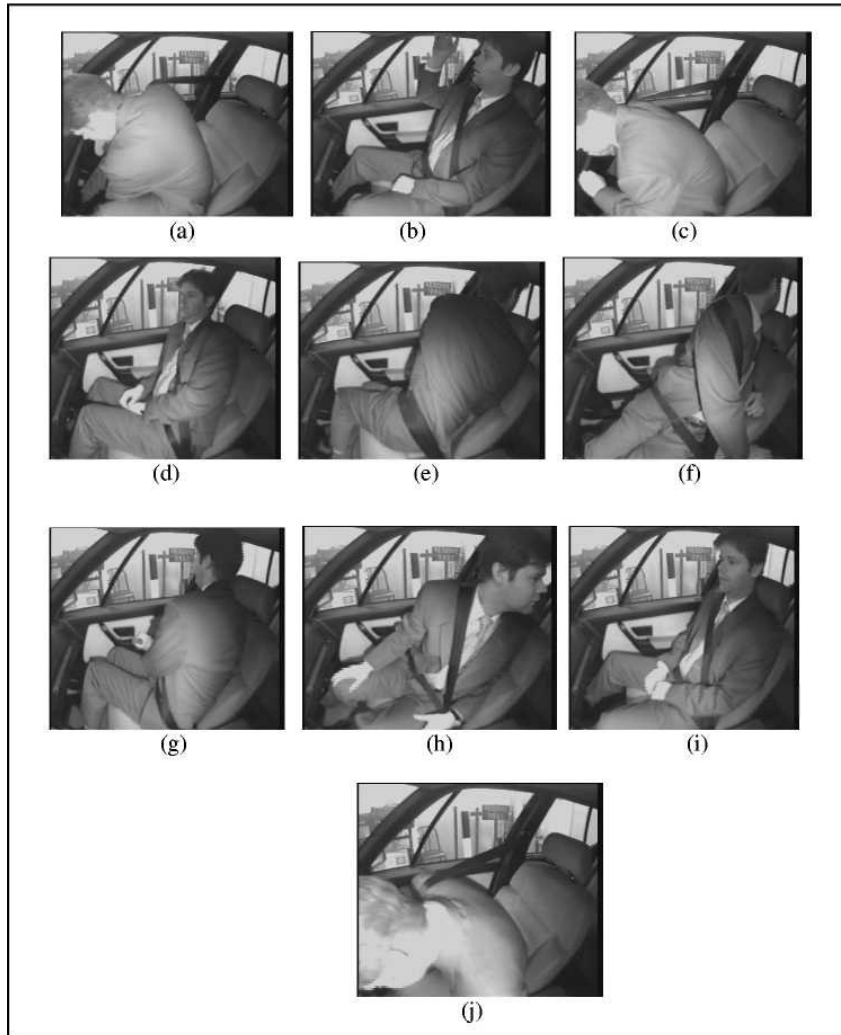
Di samping itu, juga ingin dinilai keberkesanan kaedah gabungan AKU dan analisis diskriminan dalam mengelaskan imej kedudukan penumpang dikaji.

Untuk menjalankan kajian ini, imej kedudukan penumpang di dalam kereta dipilih sebagai data sampel. Terdapat sepuluh kelas kedudukan penumpang, iaitu "floor", "hand", "dash board", "lean", "turn right", "turn left", "standard", "radio", "back right" dan "back left". Sepuluh kelas imej ini menunjukkan sepuluh jenis kedudukan yang mungkin bagi seseorang penumpang di dalam kereta. Kelas-kelas kedudukan itu adalah mengikut takrifan pakar daripada PSA Peugeot Citroen bagi kajian keselamatan dalam kenderaan (Liong, 2001). Kesukaran dalam membezakan kelas-kelas ini adalah apabila sesuatu kedudukan itu berada dalam fasa peralihan ke kedudukan lain, misalnya antara "standard" dan "lean". Suatu siri kedudukan penumpang telah dilakon dan dirakamkan, dan seterusnya siri imej tersebut telah diproses ke dalam imej individu untuk pemprosesan. Kira-kira sebanyak 130 imej telah diperoleh untuk setiap kedudukan tersebut. Satu set kedudukan yang tipikal bagi kelas-kelas kedudukan penumpang itu ditunjukkan dalam Rajah 1.

Imej-imej ini kemudian disegmen untuk membezakan objek yang diminati, iaitu penumpang, dari latar belakang. Teknik segmentasi yang digunakan ialah teknik pengambangan setempat. Teknik pengambangan setempat ialah suatu teknik segmentasi yang membahagikan imej kepada bahagian yang serupa mengikut satu atau beberapa nilai ambangan dan hanya piksel yang terletak di atas atau mendekati pinggir antara objek dan latar belakang dipertimbangkan. Selepas itu, fitur-fitur diekstrak daripada imej yang tersegmen. Jenis fitur yang dipilih dalam kajian ini ialah Momen Ortogon Legendre (MOL) (Jain, 1989; Liao dan Pawlak, 1996; Liong *et al.*, 2005; Mukundan dan Ramakrishnan, 1998). Fitur MOL yang diekstrak daripada imej boleh digunakan untuk mengecam kedudukan dan orientasi sesuatu objek yang dikenal pasti di dalam satah.

Proses pengekstrakan fitur dilakukan dengan menggunakan aturcara C++. Sebanyak 36 nilai MOL telah diekstrak daripada setiap imej, iaitu m_{00} , m_{10} , m_{01} , m_{11} , m_{20} , m_{02} , m_{21} , m_{12} , m_{22} , m_{30} , m_{03} , m_{31} , m_{13} , m_{32} , m_{23} , m_{33} , m_{40} , m_{04} , m_{41} , m_{14} , m_{42} , m_{24} , m_{43} , m_{34} , m_{44} , m_{50} , m_{05} , m_{51} , m_{15} , m_{52} , m_{25} , m_{53} , m_{35} , m_{54} , m_{45} , m_{55} . Kesemua nilai momen membentuk suatu fitur vektor untuk pengecaman setiap kelas kedudukan penumpang tersebut. Nilai-nilai MOL yang terhasil daripada kesemua imej-imej kedudukan yang dikaji seterusnya dimasukkan ke dalam pakej SPSS versi 12 untuk analisis seterusnya.

Pendekatan Gabungan AKU-ADL untuk Pengecaman Kedudukan Penumpang



Rajah 1: Imej tipikal daripada setiap kelas kedudukan penumpang: (a) "floor", (b) "hand", (c) "dashboard", (d) "lean", (e) "turn right", (f) "turn left", (g) "back right", (h) "back left", (i) "standard", dan (j) "radio".

Seterusnya, analisis yang penting, iaitu AKU dijalankan untuk melakukan penurunan dimensi data. Bagaimanapun sebelum analisis ini dijalankan, beberapa analisis permulaan perlu dilakukan untuk memastikan kesahihan keputusan analisis. Antaranya ialah ujian kecukupan pensampelan Kaiser-Meyer-Olkin (KMO) yang menguji kesesuaian saiz sampel dan ujian kesferaan Barlett yang memeriksa korelasi di antara pembolehubah (Field, 2005).

Seterusnya, pemilihan komponen dilakukan untuk memilih komponen-komponen utama yang menerangkan kebanyakan varians data asal. Terdapat banyak kaedah diperkenalkan untuk pemilihan komponen dalam AKU seperti rajah scree, kriteria Kaiser, kaedah *kayu patah* dan sebagainya. Strategi yang diambil bergantung pada objektif analisis (Webb, 2002). Selepas proses pemilihan komponen, matriks reja korelasi perlu disemak untuk menentukan sama ada bilangan komponen yang dipilih adalah memadai. Jika bilangan komponen yang dipilih adalah memadai, reja adalah kecil (Field, 2005; Pett *et al.*, 2003).

Putaran paksi perlu dilakukan untuk menjadikan komponen yang dihasilkan itu lebih bermakna dan lebih mudah ditafsirkan. Putaran paksi ialah proses memutar paksi keterangan komponen sekitar asalan untuk mencapai suatu struktur mudah dan penyelesaian komponen yang lebih bererti secara teori. Kaedah putaran paksi yang dipilih ialah putaran Varimax. Varimax memaksimumkan varians muatan di antara komponen dan juga memaksimumkan perbezaan antara muatan tertinggi dan terendah bagi suatu komponen tertentu, iaitu muatan yang tinggi pada suatu komponen akan menjadi lebih tinggi dan muatan yang rendah akan menjadi lebih rendah (Hair *et al.*, 1979; Pett *et al.*, 2003). Selepas proses putaran paksi, skor komponen boleh dikira daripada matriks muatan faktor yang telah diputar. Nilai-nilai skor komponen ini dijadikan pembolehubah tidak bersandar yang baru untuk ADL yang seterusnya.

ADL seterusnya dijalankan untuk mengelaskan imej-imej kedudukan penumpang kepada kelas-kelas yang sepatutnya. Dalam analisis ini, pertama sekali ujian Box-M dilakukan untuk menguji kehomogenan matriks kovarians. Matriks kovarians yang tidak sama akan mempengaruhi proses klasifikasi secara negatif. Tetapi, terdapat bukti menunjukkan bahawa ADL tidak sensitif kepada penyimpangan andaian itu kecuali jika penyimpangan itu adalah terlampau (Field, 2005; Hair *et al.*, 1979).

ADL melibatkan proses menerbitkan fungsi diskriminan yang signifikan dan selepas itu menggunakan fungsi-fungsi itu untuk melakukan

klasifikasi. Untuk mendapatkan fungsi diskriminan, dua kaedah pengiraan boleh diguna, iaitu kaedah serentak dan kaedah langkah demi langkah. Dalam kajian ini, kaedah langkah demi langkah telah digunakan. Kaedah ini melibatkan proses memasukkan pembolehubah tidak bersandar ke dalam fungsi diskriminan satu demi satu berdasarkan kepada kuasa diskriminan (Hair *et al.*, 1979). Kuasa diskriminan suatu pembolehubah tidak bersandar boleh dinilai dengan ukuran lambda Wilks, kesan Hotelling, kriteria Pillai, jarak Mahalanobis dan ukuran Rao's V. Ukuran yang digunakan dalam kajian ini ialah jarak Mahalanobis dan lambda Wilks. Jarak Mahalanobis, D^2 ialah suatu ukuran jarak antara dua kelas yang menjana pengiraan jarak ini (Webb, 2002). Lambda Wilks pula ialah statistik umum yang digunakan untuk menguji kesamaan sentroid kelas. Semakin kecil nilai statistik lambda Wilks, semakin besar kesignifikanan berstatistik antara sentroid kelas (Hair *et al.*, 1979). Pembolehubah tidak bersandar yang mempunyai kuasa diskriminan yang signifikan patut dimasukkan ke dalam fungsi diskriminan untuk mengklasifikasikan kelas dengan optimum (Deluzio dan Astephen, 2007).

Selepas fungsi diskriminan dihasilkan, ia perlu dinilai sama ada boleh membezakan kelas dengan signifikan. Penilaian ini dilakukan dengan menjalankan ujian lambda Wilks dan ujian khi kuasa dua ke atas setiap fungsi diskriminan. Selepas itu, proses klasifikasi dijalankan dengan pengelasan data asal dan pengesahan silang. Dalam pengesahan silang, set data bersaiz n dipartisikan kepada dua bahagian. Fungsi diskriminan diterbitkan dengan menggunakan set data pertama dan kemudian fungsi itu diuji dengan menggunakan set data kedua. Kaedah pengesahan silang yang digunakan ialah kaedah "*keluarkan-satu*", iaitu setiap cerapan diklasifikasikan dengan fungsi yang dikira dari semua kes kecuali cerapan itu sendiri (Hair *et al.*, 1979; Webb, 2002).

Akhirnya, pentafsiran yang sesuai dibuat terhadap hasil yang diperolehi. Ini melibatkan menyemak fungsi diskriminan untuk menentukan kepentingan relatif setiap pembolehubah tidak bersandar dalam membezakan setiap kelas. Ini boleh dilakukan dengan memerhatikan nilai pekali terpiawai fungsi diskriminan kanonikal dan nilai muatan diskriminan. Pembolehubah tidak bersandar dengan pekali terpiawai fungsi diskriminan kanonikal yang lebih besar menyumbang lebih banyak kepada kuasa diskriminan fungsi berbanding dengan pembolehubah dengan pekali terpiawai yang lebih kecil. Selain itu, muatan diskriminan yang boleh diperolehi dari matriks struktur mengukur korelasi linear mudah antara setiap pembolehubah tidak bersandar dan fungsi diskriminan. Muatan diskriminan menunjukkan varians pembolehubah tidak bersandar yang berkongsi dengan fungsi

diskriminan. Dengan ini, sumbangan relatif setiap pembolehubah tidak bersandar kepada fungsi diskriminan boleh diketahui (Field, 2005; Hair *et al.*, 1979).

Selain itu, untuk mengetahui kelas yang didiskriminasi oleh suatu fungsi tertentu dengan baik, perlu diperhatikan jadual "Fungsi pada sentroid kelas". Sentroid menandakan lokasi yang paling tipikal bagi suatu individu dari suatu kelas tertentu. Untuk suatu fungsi diskriminan tertentu, kelas-kelas dengan nilai sentroid yang berlawanan tanda dibezakan oleh fungsi itu. Tambahan pula, semakin jauh berbeza nilai sentroid, semakin baik sesuatu fungsi itu dapat membezakan dua kelas yang terlibat. Untuk menggambarkan serakan data, graf serakan boleh diplot. Graf serakan memplotkan skor diskriminan untuk setiap cerapan dan skor itu digolongkan mengikut kelas. Dengan memerhatikan graf serakan, sebarang pertindihan data antara kelas boleh dikesan dengan mudah (Field, 2005).

KEPUTUSAN UJIKAJI DAN ANALISIS

Bahagian ini membincangkan keputusan uji kaji yang diperoleh daripada analisis yang telah dilaksanakan. Ia meliputi hasil ujian kecukupan pensampelan Kaiser-Meyer-Olkin, Ujian Kesferaan Barlett, pemilihan komponen, penyemakan reja dan putaran paksi dalam AKU, dan hasil pengelasan menggunakan ADL.

Analisis Komponen Utama (AKU)

(i) Ujian Kecukupan Pensampelan Kaiser-Meyer-Olkin (KMO)

JADUAL 1: Hasil ujian KMO dan ujian Bartlett (dengan 36 fitur)

Ukuran Kecukupan Pensampelan Kaiser-Meyer-Olkin		0.620
Ujian Kesferaan Bartlett	Khi Kuasa Dua	120152.134
	Darjah Kebebasan	630
	Nilai- <i>p</i>	0.000

Daripada Jadual 1, didapati bahawa nilai KMO = 0.620. Merujuk kepada Field (2005) dan Pett *et al.* (2003), nilai ini menunjukkan kecukupan pensampelan adalah sederhana. Nilai KMO untuk pembolehubah individu dihasilkan pada pepenjur matriks korelasi anti-imej. Daripada

matriks tersebut, didapati bahawa bukan semua nilai pepenjuru melebihi 0.5. Jadi, fitur-fitur yang mempunyai nilai pepenjuru kurang daripada 0.5 disingkirkan sehingga semua nilai pepenjuru melebihi 0.5. Akhirnya, fitur yang digunakan dalam analisis seterusnya ialah m_{10} , m_{20} , m_{12} , m_{30} , m_{31} , m_{32} , m_{33} , m_{40} , m_{04} , m_{14} , m_{42} , m_{24} , m_{43} , m_{34} , m_{50} , M_{05} , m_{51} , m_{15} , m_{25} , m_{53} , m_{35} , m_{54} , m_{45} , m_{55} . Analisis dijalankan sekali lagi dengan menggunakan 24 fitur tersebut dan nilai KMO yang baru ialah 0.814 (Jadual 2). Ini menunjukkan kecukupan pensampelan adalah sangat baik.

JADUAL 2: Hasil ujian KMO dan ujian Bartlett (dengan 24 fitur)

Ukuran Kecukupan Pensampelan Kaiser-Meyer-Olkin		0.814
Ujian Kesferaan Bartlett	Khi Kuasa Dua	63294.202
	Darjah Kebebasan	276
	Nilai- p	0.000

(ii) Ujian Kesferaan Barlett

Ujian kesferaan Bartlett menguji hipotesis nol bahawa matriks korelasi ialah matriks identiti, iaitu tiada hubungan di antara pembolehubah (Field, 2005; Pett *et al.*, 2003). Daripada Jadual 2, nilai- p adalah <0.05 , iaitu hipotesis nol ditolak. Ini membawa maksud kebarangkalian matriks korelasi ialah matriks identiti adalah amat rendah. Maka, dapat disimpulkan bahawa matriks korelasi bukan matriks identiti.

(iii) Pemilihan Komponen

Kriteria Kaiser digunakan untuk memilih komponen, iaitu pembolehubah yang nilai eigennya lebih daripada 1 dipilih. Daripada Jadual 3, didapati 5 komponen utama yang nilai eigennya melebihi 1 telah dipilih dan penurunan fitur tercapai.

(iv) Penyemakan Reja

Daripada matrik reja korelasi, didapati terdapat 35 reja (12%) yang nilainya melebihi 0.05. Peratusan ini adalah kecil maka dapat dirumuskan bahawa bilangan komponen yang telah dipilih itu adalah memadai.

(v) Putaran Paksi

Putaran dapat mengoptimumkan struktur komponen dan menyamakan kepentingan relatif bagi lima komponen tersebut. Jumlah varians yang diterangkan oleh setiap komponen selepas putaran dipaparkan dalam Jadual 4. Didapati jumlah varians yang diterangkan oleh kesemua lima komponen ini tidak mengubah, iaitu sebanyak 89.678%, tetapi jumlah ini telah diagihkan di antara lima komponen tersebut. Sebelum putaran, komponen 1 dan komponen 2 menerangkan lebih banyak varians, iaitu sebanyak 48.517% dan 17.100%. Tetapi, selepas putaran, jumlah varians yang diterangkan oleh dua komponen ini telah berkurang ke 42.359% dan 13.265% masing-masing. Varians yang dikurangkan ini telah diagihkan ke komponen yang lain sehingga berlaku peningkatan jumlah varians yang diterangkan oleh komponen-komponen lain, iaitu komponen 3 meningkat dari 10.102% ke 12.431%, komponen 4 meningkat dari 8.348% ke 11.457%, dan komponen 5 meningkat dari 5.611% ke 10.167%.

Analisis Diskriminan Linear (ADL)

Selepas AKU dijalankan, skor komponen bagi 5 komponen utama yang terpilih digunakan sebagai pembolehubah tidak bersandar dalam ADL dan diwakili oleh *skor 1*, *skor 2*, *skor 3*, *skor 4* dan *skor 5*.

JADUAL 3: Jumlah varians yang diterangkan

Komponen	Nilai Eigen Awal			Muatan Jumlah Kuasa Dua Selepas Pemilihan		
	Jumlah	Varians (%)	Kumulatif (%)	Jumlah	Varians (%)	Kumulatif (%)
1	11.644	48.517	48.517	11.644	48.517	48.517
2	4.104	17.100	65.617	4.104	17.100	65.617
3	2.425	10.102	75.720	2.425	10.102	75.720
4	2.003	8.348	84.067	2.003	8.348	84.067
5	1.347	5.611	89.678	1.347	5.611	
6	.821	3.422	93.101			
7	.372	1.550	94.651			
8	.273	1.137	95.788			
9	.232	.965	96.752			
10	.158	.660	97.412			
11	.141	.588	98.000			
12	.090	.376	98.376			
13	.080	.331	98.707			
14	.057	.239	98.946			

JADUAL 3: Jumlah varians yang diterangkan (sambungan)

Komponen	Nilai Eigen Awal			Muatan Jumlah Kuasa Dua Selepas Pemilihan		
	Jumlah	Varians (%)	Kumulatif (%)	Jumlah	Varians (%)	Kumulatif (%)
15	.054	.226	99.172			
16	.050	.209	99.381			
17	.039	.163	99.544			
18	.030	.125	99.669			
19	.025	.106	99.774			
20	.018	.074	99.849			
21	.013	.056	99.905			
22	.011	.048	99.953			
23	.007	.031	99.983			
24	.004	.017	100.000			

JADUAL 4: Jumlah varians yang diterangkan selepas putaran

Komponen	Muatan Jumlah Kuasa Dua Selepas Putaran Kuasa Dua Selepas Putaran		
	Jumlah	Varians (%)	Kumulatif (%)
1	10.166	42.359	42.359
2	3.184	13.265	55.624
3	2.983	12.431	68.055
4	2.750	11.457	79.511
5	2.440	10.167	89.678

(i) Pengujian Kehomogenan Matriks Kovarians

Daripada Jadual 5, didapati nilai- p adalah <0.05 . Ini membawa maksud kebarangkalian bahawa matriks kovarians bagi sepuluh kelas imej adalah sama adalah amat rendah. Maka, dengan nilai- p ini, hipotesis nol ditolak. Kita dapat menyimpulkan bahawa matriks kovarians bagi sepuluh kelas adalah tidak homogen. Walaupun andaian kehomogenan matriks kovarians tidak dapat dipenuhi, terdapat bukti menunjukkan bahawa ADL tidak sensitif kepada penyimpangan andaian-andaian itu kecuali jika penyimpangan itu adalah terlampau. Ini adalah tepat terutamanya dalam kes saiz sampel besar.

JADUAL 5: Hasil Ujian Box-M

Box-M	9706.965
F	70.800
Darjah Kebebasan 1	135
Darjah Kebebasan 2	1655887.656
Nilai $-p$	0.000

(ii) Penilaian Setiap Pembolehubah Tidak Bersandar

Sebelum suatu pembolehubah tidak bersandar boleh digunakan untuk melakukan analisis, ia perlu disemak sama ada ia signifikan dalam membezakan antara kelas jika hanya pembolehubah itu yang digunakan untuk melakukan diskriminan. Ini boleh dilakukan dengan menggunakan analisis ANOVA univariat, iaitu suatu ujian kesamaan min kelas.

JADUAL 6: Hasil ANOVA univariat (ujian kesamaan min kelas)

	Lambda Wilks	F	Darjah Kebebasan 1	Darjah Kebebasan 2	Nilai $-p$
skor 1	.018	7663.357	9	1282	.000
skor 2	.212	528.037	9	1282	.000
skor 3	.101	1261.974	9	1282	.000
skor 4	.064	2082.067	9	1282	.000
skor 5	.078	1690.555	9	1282	.000

Daripada Jadual 6, diperhatikan bahawa nilai $-p$ bagi semua pembolehubah tidak bersandar adalah <0.05 , jadi hipotesis nol ditolak. Maka dapat disimpulkan bahawa semua pembolehubah tidak bersandar dapat membezakan antara kelas dengan signifikan jika digunakan berasingan.

(iii) Penerbitan Fungsi Diskriminan

Jadual 7 ialah hasil yang diperolehi dari kaedah langkah demi langkah berdasarkan lambda Wilks. Ia menunjukkan pembolehubah tidak bersandar yang dimasukkan ke dalam fungsi diskriminan pada setiap langkah. Skor yang mempunyai nilai lambda Wilks yang paling kecil dan nilai-F separa yang paling besar dipilih pada setiap langkah. Kita boleh menyusun kuasa diskriminan lima pembolehubah tidak bersandar ini dalam tertib menurun seperti berikut: skor 1, skor 4, skor 5, skor 3, skor 2, iaitu skor 1 paling diskriminan dan skor 2 paling tidak diskriminan.

Bagi kaedah langkah demi langkah berdasarkan jarak Mahalanobis pula, hasil yang diperoleh ditunjukkan dalam Jadual 8. Skor yang mempunyai jarak Mahalanobis antara dua kelas terdekat yang paling besar akan dipilih dalam setiap langkah. Kuasa diskriminan lima pembolehubah tidak bersandar ini boleh disusun dalam tertib menurun seperti berikut: *skor 1*, *skor 2*, *skor 3*, *skor 5*, *skor 4*, iaitu *skor 1* paling diskriminan dan *skor 4* paling tidak diskriminan.

JADUAL 7: Hasil kaedah langkah demi langkah berdasarkan lambda Wilks

Langkah		Tolerans	Nilai -F Separa	Lambda Wilks
0	skor 1	1.000	7663.357	.018
	skor 2	1.000	528.037	.212
	skor 3	1.000	1261.974	.101
	skor 4	1.000	2082.067	.064
	skor 5	1.000	1690.555	.078
1	skor 2	0.99	528.230	.004
	skor 3	0.936	1356.706	.003
	skor 4	0.760	2782.462	.001
	skor 5	0.995	1697.750	.001
2	skor 2	0.652	884.124	.000
	skor 3	0.767	1687.003	.000
	skor 5	0.883	1930.257	.000
3	skor 2	0.555	1064.015	.000
	skor 3	0.736	1761.709	.000
4	skor 2	0.445	1358.743	.000

JADUAL 8: Hasil kaedah langkah demi langkah berdasarkan jarak Mahalanobis

Langkah		Nilai -F Separa	Jarak Mahalanobis	Antara Kelas
0	skor 1	7663.357	.418	<i>lean dan standard</i>
	skor 2	528.037	.001	<i>turn left dan radio</i>
	skor 3	1261.974	.23	<i>hand dan turn right</i>
	skor 4	2082.067	.001	<i>hand dan back left</i>
	skor 5	1690.555	.002	<i>standard dan radio</i>
1	skor 2	528.230	3.806	<i>turn right dan back left</i>
	skor 3	1356.706	.689	<i>lean dan standard</i>
	skor 4	2782.462	1.413	<i>hand dan standard</i>
	skor 5	1697.750	1.489	<i>dashboard dan radio</i>
2	skor 3	1370.450	7.102	<i>lean dan standard</i>
	skor 4	4334.392	5.499	<i>turn right dan back left</i>
	skor 5	1713.730	6.692	<i>hand dan standard</i>
3	skor 4	6871.465	7.106	<i>lean dan standard</i>
	skor 5	1904.895	10.308	<i>lean dan standard</i>
4	skor 4	8198.930	11.028	<i>lean dan standard</i>

Didapati bahawa susunan kuasa diskriminan bagi kedua-dua kaedah ini adalah tidak sama. Percanggahan ini disebabkan oleh aspek diskriminasi yang ditekankan oleh kedua-dua kaedah ini adalah berbeza (Teo, 2006). Tetapi, kedua-dua kaedah ini bersetuju bahawa skor 1 merupakan pembolehubah tidak bersandar yang paling diskriminan antara kelas.

(iv) Penilaian Fungsi Diskriminan Kanonikal

JADUAL 9: Hasil ujian lambda Wilks dan ujian khi kuasa dua

Pengujian Fungsi	Lambda Wilks	Khi Kuasa Dua	Darjah Kebebasan	Nilai -p
1 hingga 5	.000	18814.167	45	.000
2 hingga 5	.000	12159.128	32	.000
3 hingga 5	.002	8058.080	21	.000
4 hingga 5	.031	4467.942	12	.000
5	.236	1854.155	5	.000

Didapati bahawa nilai-p bagi semua fungsi yang diuji adalah <0.05 . Maka, boleh disimpulkan bahawa semua fungsi diskriminan dapat mendiskriminasi dengan signifikan.

JADUAL 10: Nilai eigen dan korelasi kanonikal setiap fungsi diskriminan

Fungsi	Nilai Eigen	Varians (%)	Kumulatif (%)	Korelasi Kanonikal
1	177.586	78.5	78.5	.997
2	23.415	88.8	88.8	.979
3	15.398	95.6	95.6	.969
4	6.663	98.6	98.6	.932
5	3.240	100.0	100.0	.874

Untuk mengetahui fungsi diskriminan yang paling diskriminan, nilai eigen dan korelasi kanonikal bagi setiap fungsi dipertimbangkan. Nilai eigen dan korelasi kanonikal yang tinggi menunjukkan suatu fungsi dapat mendiskriminasi dengan baik. Daripada Jadual 10, didapati bahawa fungsi 1 mempunyai nilai eigen dan korelasi kanonikal yang tertinggi. Maka dapat dirumuskan bahawa fungsi 1 adalah fungsi yang paling diskriminan. Perhatikan bahawa fungsi 1 juga menerangkan kebanyakan varians dalam data, iaitu menerangkan 78.5% varians daripada jumlah varians.

(v) Hasil Pengelasan

Daripada Jadual 11, didapati kadar jaya adalah 100% baik menggunakan pengelasan data asal mahupun pengelasan silang. Keputusan ini menunjukkan bahawa fungsi diskriminan dapat mengklasifikasikan data ini dengan baik, iaitu semua kelas telah dikelaskan dengan begitu baik sekali, iaitu 100% ke dalam kelas yang sepatutnya. Ini menunjukkan objektif kajian untuk mengelaskan imej-imej kedudukan penumpang di dalam kereta kepada kelas-kelas yang betul telah tercapai.

JADUAL 11: Matriks Hasil Pengelasan Kedudukan Penumpang

		Kelas asal				Kelas diramal						Jumlah	
		<i>floor</i>	<i>hand</i>	<i>dash-board</i>	<i>lean</i>	<i>tum right</i>	<i>tum left</i>	<i>Standard</i>	<i>radio</i>	<i>back right</i>	<i>back left</i>		
Pengelasan data asal	<i>floor</i>	130	0	0	0	0	0	0	0	0	0	130	
	<i>hand</i>	0	130	0	0	0	0	0	0	0	0	130	
	<i>dash-board</i>	0	0	130	0	0	0	0	0	0	0	130	
	<i>lean</i>	0	0	0	130	0	0	0	0	0	0	130	
	<i>tum right</i>	0	0	0	0	130	0	0	0	0	0	130	
	<i>tum left</i>	0	0	0	0	0	130	0	0	0	0	130	
	<i>standard</i>	0	0	0	0	0	0	130	0	0	0	130	
	<i>radio</i>	0	0	0	0	0	0	0	121	0	0	121	
	<i>back right</i>	0	0	0	0	0	0	0	0	130	0	130	
	<i>back left</i>	0	0	0	0	0	0	0	0	0	131	131	
	%	<i>floor</i>	100.0	.0	.0	.0	.0	.0	.0	.0	.0	.0	100.0
		<i>hand</i>	.0	100.0	.0	.0	.0	.0	.0	.0	.0	.0	100.0
		<i>dash-board</i>	.0	.0	100.0	.0	.0	.0	.0	.0	.0	.0	100.0
		<i>lean</i>	.0	.0	.0	100.0	.0	.0	.0	.0	.0	.0	100.0
	<i>tum right</i>	.0	.0	.0	.0	100.0	.0	.0	.0	.0	.0	100.0	
	<i>tum left</i>	.0	.0	.0	.0	.0	100.0	.0	.0	.0	.0	100.0	
	<i>standard</i>	.0	.0	.0	.0	.0	.0	100.0	.0	.0	.0	100.0	
	<i>radio</i>	.0	.0	.0	.0	.0	.0	.0	100.0	.0	.0	100.0	
	<i>back right</i>	.0	.0	.0	.0	.0	.0	.0	.0	100.0	.0	100.0	
	<i>back left</i>	.0	.0	.0	.0	.0	.0	.0	.0	.0	100.0	100.0	

JADUAL 11: Matriks Hasil Pengelasan Kedudukan Penumpang (sambungan)

	Kelas asal	Kelas diramal										Jumlah	
		<i>floor</i>	<i>hand</i>	<i>dash-board</i>	<i>lean</i>	<i>turn right</i>	<i>turn left</i>	<i>Standard</i>	<i>radio</i>	<i>back right</i>	<i>back left</i>		
Pengesahan Silang Bilangan	<i>floor</i>	130	0	0	0	0	0	0	0	0	0	130	
	<i>hand</i>	0	130	0	0	0	0	0	0	0	0	130	
	<i>dash-board</i>	0	0	130	0	0	0	0	0	0	0	130	
	<i>lean</i>	0	0	0	130	0	0	0	0	0	0	130	
	<i>turn right</i>	0	0	0	0	130	0	0	0	0	0	130	
	<i>turn left</i>	0	0	0	0	0	130	0	0	0	0	130	
	<i>standard</i>	0	0	0	0	0	0	130	0	0	0	130	
	<i>radio</i>	0	0	0	0	0	0	0	121	0	0	121	
	<i>back right</i>	0	0	0	0	0	0	0	0	130	0	130	
	<i>back left</i>	0	0	0	0	0	0	0	0	0	131	131	
	%	<i>floor</i>	100.0	.0	.0	.0	.0	.0	.0	.0	.0	.0	100.0
		<i>hand</i>	.0	100.0	.0	.0	.0	.0	.0	.0	.0	.0	100.0
		<i>dash-board</i>	.0	.0	100.0	.0	.0	.0	.0	.0	.0	.0	100.0
	<i>lean</i>	.0	.0	.0	100.0	.0	.0	.0	.0	.0	.0	100.0	
	<i>turn right</i>	.0	.0	.0	.0	100.0	.0	.0	.0	.0	.0	100.0	
	<i>turn left</i>	.0	.0	.0	.0	.0	100.0	.0	.0	.0	.0	100.0	
	<i>standard</i>	.0	.0	.0	.0	.0	.0	100.0	.0	.0	.0	100.0	
	<i>radio</i>	.0	.0	.0	.0	.0	.0	.0	100.0	.0	.0	100.0	
	<i>back right</i>	.0	.0	.0	.0	.0	.0	.0	.0	100.0	.0	100.0	
	<i>back left</i>	.0	.0	.0	.0	.0	.0	.0	.0	.0	100.0	100.0	

*100.0% kes dikelaskan dengan betul menggunakan pengelasan data asal mahupun pengesahan silang

(vi) Penentuan Kepentingan Relatif Setiap Pembolehubah Tidak Bersandar dalam Mendiskriminasi Setiap Kelas

Dalam Jadual 12, pekali terpiawai fungsi diskriminan kanonikal ditunjukkan. *Skor 4* memberikan sumbangan yang paling besar kepada fungsi 1 dan fungsi 2. Manakala fungsi 3, 4 dan 5 masing-masing disumbangkan paling banyak oleh *skor 5*, *skor 3* dan *skor 2*.

JADUAL 12 : Pekali terpiawai fungsi diskriminan kanonikal

	Fungsi				
	1	2	3	4	5
skor 1	1.484	-0.355	-0.107	-0.014	0.010
skor 2	1.000	0.646	0.178	-0.032	0.892
skor 3	0.787	0.006	0.779	0.680	-0.048
skor 4	1.696	0.863	0.236	0.235	-0.170
skor 5	0.417	0.551	-0.825	0.416	-0.029

Dalam Jadual 13, matriks struktur ditunjukkan. Pembolehubah tidak bersandar disusun mengikut saiz mutlak korelasi di dalam fungsi. Didapati fungsi 1 dan 2 berkorelasi tinggi dengan skor 1, iaitu mereka disumbangkan paling banyak oleh skor 1. Skor 5 memberikan sumbangan yang paling banyak kepada fungsi 3. Manakala fungsi 4 dan 5 masing-masing berkorelasi tinggi dengan skor 3 dan skor 2. Pada keseluruhannya, skor 1 merupakan pembolehubah tidak bersandar yang memberikan paling banyak sumbangan dalam membezakan kelas, diikuti dengan skor 3, skor 5, skor 2, dan akhirnya skor 4.

JADUAL 13 : Matriks struktur

	Fungsi				
	1	2	3	4	5
skor 1	0.455	-0.798	-0.358	-0.100	0.135
skor 2	0.043	0.002	0.468	0.875	-0.112
skor 3	0.030	0.290	-0.648	0.698	-0.089
skor 4	0.026	0.124	0.051	-0.020	0.990
skor 5	0.148	0.552	0.225	-0.478	-0.628

Didapati bahawa pentafsiran tentang kepentingan relatif setiap pembolehubah tidak bersandar dalam mendiskriminasi setiap kelas dengan menggunakan nilai pekali terpiawai fungsi diskriminan kanonikal dan nilai muatan diskriminan adalah tidak sama. Jadual 14 menunjukkan perbandingan antara kedua-dua nilai ini dalam mentafsirkan kepentingan relatif ini.

JADUAL 14: Perbandingan pembolehubah tidak bersandar yang memberikan sumbangan paling besar kepada setiap fungsi berdasarkan nilai pekali terpiawai fungsi diskriminan kanonikal dan nilai muatan diskriminan

Fungsi	Nilai Pekali Terpiawai Fungsi Diskriminan Kanonikal	Nilai Muatan Diskriminan
1	skor 4	skor 1
2	skor 4	skor 1
3	skor 5	skor 5
4	skor 3	skor 3
5	skor 2	skor 2

Daripada jadual ini, didapati bahawa pembolehubah tidak bersandar yang mendominasi fungsi 3, 4, dan 5 adalah sama, iaitu skor 5, skor

3, dan skor 2 masing-masing. Manakala penyumbang paling besar bagi fungsi 1 dan 2 adalah skor 4 berdasarkan nilai pekali terpiawai fungsi diskriminan kanonikal dan merupakan skor 1 menurut nilai muatan diskriminan. Tetapi, oleh kerana nilai muatan diskriminan adalah lebih kukuh daripada nilai pekali terpiawai fungsi diskriminan kanonikal (Hair *et al.*, 1979), maka keputusan boleh dibuat bahawa fungsi 1 dan 2 disumbang paling banyak oleh skor 1.

(vii) Fungsi pada Sentroid Kelas


Daripada Jadual 15, didapati bahawa fungsi 1 membezakan kelas *floor* dan *turn left* dengan baik kerana nilai sentroid kedua-dua kelas ini adalah paling jauh berbeza. Bagi fungsi 2, dua kelas yang dibezakan olehnya dengan baik ialah kelas *floor* dan *radio*. Kelas yang dibezakan oleh fungsi 3, 4 dan 5 dengan baik masing-masing ialah kelas *lean* dan *back left*, kelas *standard* dan *back right*, serta kelas *radio* dan *back left*.

JADUAL 15: Fungsi pada sentroid kelas

Kelas	Fungsi				
	1	2	3	4	5
<i>floor</i>	26.677	6.929	1.017	-2.896	0.265
<i>hand</i>	-8.828	4.343	3.144	-0.653	2.617
<i>dashboard</i>	21.915	-3.196	0.686	2.068	-1.391
<i>lean</i>	-8.809	0.899	4.755	2.186	-1.474
<i>turn right</i>	-8.699	-4.123	2.564	-1.092	-1.997
<i>turn left</i>	-9.519	1.194	-6.022	-0.809	1.887
<i>standard</i>	-8.350	2.811	3.651	2.667	0.916
<i>radio</i>	9.227	-9.628	-1.997	1.999	2.629
<i>back right</i>	-8.001	-4.451	-0.299	-5.516	-0.998
<i>back left</i>	-4.935	4.521	-7.578	2.168	-2.252

(viii) Penaburan Data

Merujuk kepada Rajah 2, data adalah tertabur dengan baik terutamanya bagi kelas *floor*, *dashboard* dan *radio*. Data bagi ketiga-tiga kelas ini terasing dari data kelas lain dengan jelas. Maka boleh dijangka bahawa ketiga-tiga kelas ini boleh dibezakan dan dikelaskan dengan lebih baik dibanding dengan kelas lain. Pertindihan data berlaku bagi kelas *turn right* dan *back right*. Selain itu, data bagi kelas *lean*, *turn left*, *standard* dan *handjuga* bertindih dan data bagi kelas *back left* juga tertabur berhampiran dengan data kelas-kelas itu. Secara keseluruhannya, penaburan data memuaskan. Jadi, dapat dirumuskan bahawa ADL telah dilakukan dengan sempurna.



Rajah 2: Graf serakan bagi fungsi diskriminan kanonikal 1 dan 2

KESIMPULAN

Hasil kajian menunjukkan kaedah AKU-ADL sesuai digunakan sekalipun dalam masalah pengecaman pola yang melibatkan dimensi tinggi. Masalah dimensi tinggi dapat diselesaikan dengan menjalankan penurunan dimensi melalui AKU. Selepas itu, ADL boleh dijalankan terhadap data yang dimensinya telah diturunkan.

Dalam kajian ini, AKU berjaya menurunkan fitur data kedudukan penumpang daripada 36 fitur kepada 5 fitur sahaja. Selain itu, AKU juga berjaya memilih fitur yang dapat mengelaskan kedudukan penumpang dengan sempurna. Ini dibuktikan dengan hasil pengelasan 100% selepas ADL dijalankan. Sebagai kesimpulannya, pendekatan menggunakan gabungan AKU-ADL amat berkesan dalam mengelaskan imej kedudukan penumpang yang dikaji.

PENGHARGAAN

Penulis ingin merakamkan ucapan terima kasih kepada *PSA Peugeot Citroen* dan *Cranfield University* kerana telah membenarkan imej-imej kedudukan penumpang dalam kereta (Liong, 2001) digunakan dalam kajian ini.

RUJUKAN

- Belhumeur, P.N., J.P. Hespanha dan D.J. Kriegman. 1997. Eigenface vs. Fisherface: Recognition using class specific linear projection. *IEEE Trans. Pattern Analysis and Machine Intelligence* **19**: 711-720.
- Boverie, S. 2002. A new class of intelligent sensors for the inner space monitoring of the vehicle of the future. *Control Engineering Practice* **10**: 1169-1178.
- Brown, C. 1988. Introduction, dlm. *Advances in Computer Vision*, pnyt. C. Brown (Lawrence Erlbaum Associates).
- Davies, E.R. 1997. *Machine Vision*. Edisi ke-2. San Diego: Academic Press.
- Deluzio, K.J. dan J.L. Astephen. 2007. Biomechanical features of gait waveform data associated with knee osteoarthritis: An applications of principal component analysis. *Gait & Posture* **25**: 86-93.
- Destéfanis, E.A., E. Kienzle, L.R. Canali dan M.R. Modesti. 2000. Occupant detection using support vector machines with a polinomial kernel function. Dlm. B. Gopalakrishnan dan A. Gunasekaran, *Proceedings of SPIE 4192: Intelligent Systems in Design & Manufacturing III*, pp. 270-277.
- Field, A. 2005. *Discovering Statistics using SPSS*. Edisi ke-2. Thousand Oaks: Sage Publications.
- Gonzalez, R.C. and R.E. Woods. 2002. *Digital Image Processing*. Edisi ke-2. Upper Saddle River: Prentice-Hall Inc.

- Gottschalk, M.A. 1997. Automotive sensors: Sensors make cars smarter. *Design News Magazine*. October 6, 1997. <http://www.designnews.com/article/CA150635.html> (18/01/2008).
- Grisoni, E.R., S.B. Pillai, T.A. Volsko, K. Mutabagani, V. Garcia et al. 2000. Pediatric airbag injuries: The ohio experience. *Journal of Pediatric Surgery* 35(2): 160-163.
- Hair, J.F., R.E. Anderson, R.L. Tatham dan B.J. Grablowsky. 1979. *Multivariate Data Analysis with Readings*. Tulsa: Petroleum Publishing Company.
- Hardin, W. 2002. Imaging takes a front seat in futuristic automobiles. *Machine Vision Online*. The Automated Imaging Association. <http://www.machinevisiononline.org/public/articles/archivedetails.cfm?id=975> (28 Mac 2008).
- Insurance Institute for Highway Safety. 1988. About Your Airbags. http://www.iihs.org/brochures/pdf/about_airbags_english.pdf (18/01/2008).
- Jähne, B. 2002. *Digital Image Processing*. Edisi ke-5. Berlin: Springer.
- Jain, A.K. 1989. *Fundamentals of Digital Image Processing*. Englewood Cliffs: Prentice-Hall.
- Johnson, R.A. dan D.W. Wichern. 2002. *Applied Multivariate Statistical Analysis*. Edisi ke-5. Upper Saddle River: Prentice-Hall Inc.
- Landau, S. dan B.S. Everitt. 2003. *A Handbook of Statistical Analyses Using SPSS*. Boca Raton: CRC Press.
- Langheim, J. et al. 2000. Carsense - New Environment Sensing for Advanced Driver Assistance Systems. <http://www-rocq.inria.fr/imara/docs/ITS-00019.pdf> (28 Mac 2008).
- Levine, M.D. 1985. Vision in Man and Machine. New York: McGraw-Hill. Liao, S.X. dan M. Pawlak. 1996. On image analysis by moments. *IEEE Trans. Pattern Analysis and Machine Intelligence* 18(3): 254-266.

- Liong, C.Y. 2001. Investigation of Vision Based System for Passenger Position Recognition, Ph.D. Thesis, Applied Mathematics and Computing, Cranfield University.
- Liong, C.Y., Abdul Aziz Jemain, Nor Azura Md Ghani dan H.C. Cheah. 2005. Menilai kesesuaian momen ortogon Legendre untuk pengelasan kedudukan penumpang yang tersegmen-sempurna menggunakan analisis diskriminan, *Prosiding Simposium Kebangsaan Sains Matematik ke XIII*, 31 Mei - 2 Jun 2005, Alor Star, Kedah. Jld. 2: 996-1005.
- Mukundan, R. dan K.R. Ramakrishnan. 1998. *Moment Function in Image Analysis: Theory and Application*. Singapore: World Scientific.
- Park, S., Y.K. Ku, M.J. Seo, D.Y. Kim, J.E. Yeon, K.M. Lee, S.C. Jeong, W.K. Yoon, C.H. Harn dan H.M. Kim. 2006. Principal component analysis and discriminant analysis (PCA-DA) for discriminating profiles of terminal restriction fragment length polymorphism (T-RFLP) in soil bacterial communities. *Soil Biology and Biochemistry* **38**: 2344-2349.
- Pett, M.A., N.R. Lackey dan J.J. Sullivan. 2003. *Making Sense of Factor Analysis*. Thousand Oaks: Sage Publication.
- Teo, Y.C. 2006. Menilai Kesesuaian Momen Ortogon Legendre untuk Pengecaman Kedudukan Penumpang yang Tersegmen Secara Teknik Pengambangan Tempatan, Kajian Kes Tahun Akhir, Pusat Pengajian Sains Matematik, Fakulti Sains dan Teknologi, UKM, Bangi.
- Webb, A. 2002. *Statistical Pattern Recognition*. Edisi ke-2. Chichester: John Wiley & Sons Inc.
- Yang, J. dan J.Y. Yang. 2003. Why can LDA be performed in PCA transformed space? *Pattern Recognition* **36**: 563-566.
- Yaremchuk, K. dan R.A. Dobie. 2001. Otologic injuries from airbag deployment. *Otolaryngology - Head and neck surgery* **125**(3): 130-134.

Zhuang, X.S. dan D.Q. Dai. 2007. Improved discriminate analysis for high-dimensional data and its application to face recognition. *Pattern Recognition* **40**: 1570-1578.