

BAB 5 IMPLEMENTASI

5.1 Spesifikasi Sistem

Dalam melakukan implementasi digunakan perangkat keras dan perangkat lunak dengan spesifikasi tertentu sehingga sistem dapat berjalan.

5.1.1 Spesifikasi Perangkat Keras

Tabel 5.1 menunjukkan komponen perangkat keras serta bagaimana spesifikasinya.

Tabel 5.1 Spesifikasi Perangkat Keras

Nama Komponen	Spesifikasi
<i>Processor</i>	<i>CPU AMD Quad-Core Processor (1,50 GHz)</i>
<i>Memory (RAM)</i>	<i>Memory 6144MB RAM</i>
<i>HDD</i>	1 TB
<i>Display</i>	<i>Display AMD Radeon™ R2 Graphics</i>

5.1.2 Spesifikasi Perangkat Lunak

Tabel 5.2 menunjukkan komponen perangkat lunak serta bagaimana spesifikasinya.

Tabel 5.2 Spesifikasi Perangkat Lunak

Nama Komponen	Spesifikasi
Bahasa Pemrograman	Python 2.7
Editor	Spyder, Notepad++
DBMS	SQLite

5.2 Implementasi Data

Berdasarkan perancangan sebelumnya, Gambar 5.1 menunjukkan implementasi basis data untuk data latih, Gambar 5.2 menunjukkan implementasi basis data untuk data uji, dan Gambar 5.3 menunjukkan perancangan basis data untuk hasil *POS-Tagging*.

odp datalatiha	
#	Dokumen : int(3)
⊞	Kelas : varchar(7)
⊞	Ulasan : varchar(2304)
⊞	Aspek : varchar(22)

Gambar 5.1 Implementasi Data Latih

Penjelasan singkat tentang atribut untuk data latih adalah sebagai berikut:

1. Dokumen, yaitu nama dokumen yang dalam kasus ini adalah nomor dokumen.
2. Kelas, yaitu kelas ulasan tersebut termasuk ke dalam kelas positif atau negatif berdasarkan pakar.
3. Ulasan, yaitu teks dokumen itu sendiri.
4. Aspek, dari hasil klasterisasi setiap dokumen akan mendapatkan aspeknya.

odp dataujia	
#	Dokumen : int(3)
⊞	Kelas : varchar(7)
⊞	Ulasan : varchar(2671)
⊞	Aspek : varchar(15)

Gambar 5.2 Implementasi Data Uji

Penjelasan singkat tentang atribut untuk data uji adalah sebagai berikut:

1. Dokumen, yaitu nama dokumen yang dalam kasus ini adalah nomor dokumen.
2. Kelas, yaitu kelas ulasan tersebut termasuk ke dalam kelas positif atau negatif berdasarkan pakar.
3. Ulasan, yaitu teks dokumen itu sendiri.
4. Aspek, dari hasil klasterisasi setiap dokumen akan mendapatkan aspeknya.

odp bona	
⊞	KATA : varchar(16)
⊞	TAG : varchar(13)

Gambar 5.3 Implementasi Data Kelas Kata

Penjelasan singkat tentang atribut untuk data latih adalah sebagai berikut:

1. Kata, yaitu daftar kata dari keseluruhan data latih.
2. Tag, yaitu kelas kata yang diambil dari Kateglo.

5.3 Implementasi Sistem

5.3.1 Proses untuk menangani basis data

Untuk menangani basis data dibuat sebuah kelas khusus dengan fungsi-fungsi sesuai keperluan data yang ingin diolah.

```
1 class DBHelper:
2     def __init__(self,
3 dbname="dataskripsi.db",latih='dataLatihA',uji='dataUjiA',bon='BONA'):
4         self.dbname = dbname
5         self.latih = latih
6         self.uji = uji
7         self.bon= bon
8         self.conn = sqlite3.connect(dbname)
9
10    def get_nama_dokumen(self):
11        stmt = "SELECT Dokumen FROM "+self.latih
12        return [x[0] for x in self.conn.execute(stmt)]
13
14    def get_nama_dokumen_uji(self):
15        stmt = "SELECT Dokumen FROM "+self.uji
16        return [x[0] for x in self.conn.execute(stmt)]
17
18    def get_data_latih(self):
19        stmt = "SELECT ulasan FROM "+self.latih
20        return [x[0] for x in self.conn.execute(stmt)]
21
22    def get_kelas_latih(self):
23        stmt = "SELECT kelas FROM "+self.latih
24        return [x[0] for x in self.conn.execute(stmt)]
25
26    def get_data_uji(self):
27        stmt = "SELECT ulasan FROM "+self.uji
28        return [x[0] for x in self.conn.execute(stmt)]
29
30    def get_kelas_uji(self):
31        stmt = "SELECT kelas FROM "+self.uji
32        return [x[0] for x in self.conn.execute(stmt)]
33
34    def get_ulasan_latih(self, kelas):
35        stmt = "select ulasan from {} WHERE Kelas =
36 (?)".format(self.latih)
37        args = (kelas, )
38        return [x[0] for x in self.conn.execute(stmt, args)]
39
40    def get_kata_nomina(self):
41        stmt = "SELECT KATA FROM {} WHERE TAG =
42 'Nomina'".format(self.bon)
43        return [x[0] for x in self.conn.execute(stmt)]
44
45    def insert_tag(self, data):
46
47        c = self.conn.cursor()
48        drop_table = 'DROP TABLE IF EXISTS {}'.format(self.bon)
49        c.execute(drop_table)
50        create_table = 'CREATE TABLE IF NOT EXISTS {} ( `KATA` TEXT,
51 `TAG` TEXT)'.format(self.bon)
52        c.execute(create_table)
53        tagidx = 'CREATE INDEX IF NOT EXISTS tagIndex ON {} (KATA
54 ASC)'.format(self.bon)
55        c.execute(tagidx)
56
57        for row in data:
```

```

58         c.execute('INSERT INTO {} VALUES (?,?)'.format(self.bon),
59 row )
60         self.conn.commit()
61
62     def set_aspek(self, aspek, dok) :
63         c = self.conn.cursor()
64         c.execute('UPDATE {} SET Aspek = "{}" WHERE Dokumen =
65 "{}"'.format(self.latih, aspek, dok) )
66         self.conn.commit()
67     def set_aspek_uji (self, aspek, dok) :
68         c = self.conn.cursor()
69         c.execute('UPDATE {} SET Aspek = "{}" WHERE Dokumen =
70 "{}"'.format(self.uji, aspek, dok) )
71         self.conn.commit()

```

Kode Program 5.1 Penanganan Basis Data

Penjelasan Kode Program 5.1 berdasarkan fungsi di dalamnya adalah sebagai berikut:

1. `__init__` adalah untuk inialisasi awal variable-bariabel yang akan dibutuhkan selanjutnya seperti nama basis data kemudian membangun koneksi ke basis data tersebut.
2. `get_nama_dokumen` adalah untuk mengambil seluruh nama dokumen atau dalam kasus ini merupakan nomor dokumen yang menjadi identitasnya pada data latih.
3. `get_nama_dokumen_uji` adalah untuk mengambil seluruh nama dokumen atau dalam kasus ini merupakan nomor dokumen yang menjadi identitasnya pada data uji.
4. `get_data_latih` adalah untuk mengambil seluruh ulasan pada data latih.
5. `get_kelas_latih` adalah untuk mengambil seluruh kelas untuk setiap ulasan pada data latih.
6. `get_data_uji` adalah untuk mengambil seluruh ulasan pada data uji.
7. `get_kelas_uji` adalah untuk mengambil seluruh kelas untuk setiap ulasan pada data uji.
8. `get_ulasan_latih` adalah untuk mengambil ulasan pada data latih yang memiliki kelas sesuai parameter (positif atau negatif).
9. `get_kata_nomina` adalah untuk mengambil kata yang memiliki kelas kata nomina.
10. `insert_tag` adalah untuk membuat data berupa kata serta kelas katanya.
11. `set_aspek` adalah untuk menambahkan data aspek kepada ulasan data latih.
12. `set_aspek` adalah untuk menambahkan data aspek kepada ulasan data uji.

5.3.2 Proses *Preprocessing* Data

Untuk melakukan klusterisasi diperlukan *Bag of Nouns*. Untuk itu pada proses ini akan dilakukan *preprocessing* hingga *pos-tagging* sehingga nantinya dapat disaring mana yang termasuk kata benda atau nomina.

```
1 def pos_tagging():
2     stopword = open('id.stopwords.02.01.2016.txt', 'r')
3     isistopword = stopword.read()
4     stopword.close()
5     sw = re.split('\n', isistopword)
6
7     list_data = db.get_data_latih()
8     list_cf = []
9     for each in list_data:
10         list_cf.append(each.lower())
11
12     list_f = []
13     for x in list_cf:
14         teks = x
15         for y in sw:
16             teks = re.sub(r'\b{}\b'.format(y), ' ', teks)
17         list_f.append(teks)
18
19     list_f2 = []
20     for x in list_f:
21         list_f2.append(re.sub(r'^A-Za-z+', ' ', x))
22
23     list_t = []
24     for each in list_f2:
25         list_t.append(re.split(' ', each))
26
27     list_word = []
28     for x in list_t:
29         for y in x:
30             if y and len(y) > 2:
31                 list_word.append(y)
32
33     set_word = set(list_word)
34     list_word = list(set_word)
35     tag_word = []
36     non_tag = []
37     for each in list_word:
38         try:
39             tag = cek_tag(each)
40             tag_word.append([each, tag])
41         except Exception as e:
42             print(e)
43             print("\n----\n")
44             print each
45             non_tag.append([each])
46             time.sleep(2)
47     db.insert_tag(tag_word)
48 def cek_tag(kata):
49     response =
50     requests.get('http://kateglo.com/api.php?format=json&phrase='+kata)
51     content = response.content.decode("utf8")
52     js = json.loads(content)
53     return js['kateglo']['lex_class_name']
```

Kode Program 5.2 Proses *Preprocessing*

Penjelasan Kode Program 5.2 adalah sebagai berikut:

1. Baris 2-5 adalah pembacaan dan penyimpanan daftar kata pada *stopwords*

ke dalam variable local.

2. Baris 9-10 adalah *case folding*, membuat semua huruf menjadi huruf kecil
3. Baris 13-17 adalah penghilangan kata yang termasuk *stopwords*
4. Baris 20-21 adalah untuk menghilangkan karakter yang bukan alfabet
5. Baris 24-25 adalah untuk tokenisasi dengan cara membagi suatu *string* berdasarkan karakter spasi.
6. Baris 28-31 adalah untuk mengumpulkan seluruh kata kedalam satu *list* dengan syarat kata tersebut memiliki Panjang karakter lebih dari dua karakter.
7. Baris 33-34 adalah untuk melakukan penghilangan kata atau token yang duplikat.
8. Baris 37-47 adalah untuk melakukan proses penentuan kelas kata untuk setiap kata dengan memanggil fungsi `cek_tag()` kemudian memasukkannya ke dalam basis data.
9. Baris 48-53 adalah untuk melakukan pemeriksaan terhadap suatu kata melalui API yang disediakan oleh *Kateglo* kemudian diambil data kelas katanya.

5.3.3 Proses Klasterisasi dengan K-Modes

5.3.3.1 Proses Klasterisasi Data Latih

Dimulai dengan pembentukan dimensi daftar dokumen dan daftar kata nomina kemudian dilakukan klasterisasi hingga diberikan sekumpulan kata yang merepresentasikan setiap klaster.

```
1
2   for x in list_bon_real:
3       c = [x for dok in list_data if re.search(r'\b{}\b'.format(x),
4 dok.lower())]
5       if len(c) > 2:
6           list_bon.append(x)
7
8   n_klaster = 6
9   vek_dok = []
10  jumlah_nomina = []
11  for x in range(len(list_data)):
12      vek_kata = []
13      for y in list_bon:
14          if re.search(r'\b{}\b'.format(y), list_data[x].lower()):
15              vek_kata.append(1)
16          else:
17              vek_kata.append(0)
18      vek_dok.append([vek_kata, str(list_nama_dokumen[x])])
19      jumlah_nomina.append(sum(vek_kata))
20
21  term_freq = {}
22  for x in range(len(list_data)):
23      term_doc = []
24      for y in list_bon:
25          term_occ = len(re.findall(r'\b{}\b'.format(y), list_data[x]
26 .lower()))
```

```

27         term_doc.append(term_occ)
28         term_freq[str(list_nama_dokumen[x])] = term_doc
29
30     centroid = []
31     centroid.append(vek_dok[2][0])
32     centroid.append(vek_dok[6][0])
33     centroid.append(vek_dok[9][0])
34     centroid.append(vek_dok[104][0])
35     centroid.append(vek_dok[51][0])
36     centroid.append(vek_dok[65][0])
37
38     cek_k = []
39
40     for iterasi in range(10):
41         centroid_value = []
42         for each in vek_dok:
43             sum_x = [None] * n_klaster
44             for x in range(len(sum_x)):
45                 sum_x[x] = []
46             temp_centroid = []
47             hd = [None] * n_klaster
48             for indx in range(len(each[0])):
49                 for indy in range(n_klaster):
50
51                     if each[0][indx] == centroid[indy][indx] or
52 centroid[indy][indx] == 2:
53                         sum_x[indy].append(0)
54                     else:
55                         sum_x[indy].append(1)
56                 for indz in range(len(hd)):
57                     hd[indz] = sum(sum_x[indz])
58                 centroid_value.append(hd)
59
60         result_cluster = []
61         for each in centroid_value:
62             closest = min(each)
63             result_cluster.append(each.index(closest)+1)
64
65         k = [None] * n_klaster
66         for indx in range(len(k)):
67             k[indx] = []
68         for x in range(len(result_cluster)):
69             for y in range(n_klaster):
70                 if result_cluster[x] == y+1:
71                     k[y].append(vek_dok[x])
72
73         for pjn in range(len(k)):
74             print 'Anggota klaster {} sebanyak {}'.format(pjn+1,
75 len(k[pjn]))
76         for kx in range(n_klaster):
77             temp_new_centroid = []
78             for x in range(len(k[kx][0][0])):
79                 mode_temp = []
80                 for y in k[kx]:
81                     mode_temp.append(y[0][x])
82                 mode_data = Counter(mode_temp)
83                 if len(mode_data.most_common()) > 1:
84                     if mode_data.most_common()[0][1] !=
85 mode_data.most_common()[1][1]:
86                         mode_val = mode_data.most_common()[0][0]
87                         temp_new_centroid.append(mode_val)
88                     elif mode_data.most_common()[0][1] ==
89 mode_data.most_common()[1][1]:
90                         temp_new_centroid.append(2)
91                 else:

```

```

92         mode_val = mode_data.most_common()[0][0]
93         temp_new_centroid.append(mode_val)
94         centroid[kx] = temp_new_centroid
95
96     if cek_k == k:
97         f = open('centroid.txt', 'w')
98         for each in centroid:
99             if each == centroid[len(centroid)-1]:
100                 f.write('{}'.format(each))
101             else:
102                 f.write('{},'.format(each))
103         f.close()
104         break
105     elif cek_k != k:
106         cek_k = k
107         continue
108
109     term_freq_sum = []
110     for i in range(n_klaster):
111         term_freq_temp = []
112         for x in k[i]:
113             term_freq_temp.append([x[1], term_freq[x[1]])]
114
115         term_freq_sum.append(term_freq_temp)
116
117     s1 = []
118     for i in range(n_klaster):
119         s2 = []
120         for x in range(len(term_freq_sum[i][0][1])):
121             sum_temp = []
122             for y in term_freq_sum[i]:
123                 sum_temp.append(y[1][x])
124             s2.append(sum(sum_temp))
125         s1.append(s2)
126
127     list_aspek = []
128     for x in range(len(s1)):
129         temp_list = {}
130         for y in range(len(s1[x])):
131             temp_list[list_bon[y]] = s1[x][y]
132         list_aspek.append(sorted(temp_list, key=temp_list.__getitem__,
133 reverse=True))
134
135     term_is = []
136     f = open('aspek.txt', 'w')
137     for i in range(n_klaster):
138         w1 = list_aspek[i][0]
139         w2 = list_aspek[i][1]
140         w3 = list_aspek[i][2]
141         term_is.append('{}-{}-{}'.format(w1, w2, w3))
142         if i == n_klaster-1:
143             f.write('{}'.format(term_is[i]))
144         else:
145             f.write('{}\n'.format(term_is[i]))
146     f.close()
147     for i in range(n_klaster):
148         for each in k[i]:
149             dok = each[1]
150             aspek = term_is[i]
151             db.set_aspek(aspek, dok)

```

Kode Program 5.3 Proses Klusterisasi Data Latih

Penjelasan Kode Program 5.3 adalah sebagai berikut:

1. Baris 2-6 adalah untuk membentuk daftar kata nomina yang kemunculannya lebih dari dua kali untuk keseluruhan dokumen.
2. Baris 11-18 adalah untuk membentuk vektor dokumen dengan nilai 1 jika suatu kata terdapat dalam dokumen tersebut dan bernilai 0 jika tidak terdapat.
3. Baris 22-28 adalah untuk membentuk vector dokumen dengan nilai kemunculan suatu kata pada dokumen tersebut. Hal ini akan digunakan nantinya saat klaster sudah terbentuk.
4. Baris 30-36 adalah untuk penentuan *centroid* awal.
5. Baris 51-55 adalah untuk pemeriksaan jika nilai suatu atribut pada dokumen dengan *centroid* sama maka akan diberikan nilai 0 dan jika berbeda akan diberikan nilai 1.
6. Baris 56-58 adalah untuk mendapatkan jarak antara dokumen dengan *centroid* dengan cara menjumlah berapa atribut yang tidak cocok kemudian semua jarak untuk semua *centroid* dihimpun.
7. Baris 61-63 adalah untuk penentuan klaster suatu dokumen dengan melihat kepada jarak terdekat atau nilai jarak terkecil.
8. Baris 65-71 membuat sebuah daftar klaster dengan anggotanya dokumen yang mana saja.
9. Baris 76-94 adalah untuk menentukan *centroid* baru dengan cara melihat modus untuk suatu atribut berdasarkan dokumen-dokumen yang ada dalam satu klaster.
10. Baris 96-100 adalah untuk pemeriksaan apakah hasil klaster pada iterasi tertentu sama dengan hasil klaster sebelumnya, jika iya maka iterasi dihentikan, jika tidak iterasi dilanjutkan hingga batas maksimal iterasi.
11. Baris 109-115 adalah untuk pembentukan vektor dokumen dengan *term frequency* berdasarkan klasternya.
12. Baris 117-125 adalah untuk melihat total kemunculan setiap kata untuk setiap klaster.
13. Baris 127-133 adalah melakukan pengurutan jumlah kemunculan kata pada setiap klaster.
14. Baris 136-141 adalah untuk mengetahui tiga kata dengan kemunculan paling banyak pada setiap klaster.
15. Baris 147-151 adalah untuk memasukkan aspek pada setiap dokumen ke dalam basis data.

5.3.3.2 Proses Pengujian Klusterisasi

Proses ini melakukan pengujian seberapa tepat suatu dokumen dimasukkan ke dalam klasternya dengan menggunakan *Silhouette Coefficient*.

```
1 def silhouette_coefficient(n_klaster, k):
2     avg_k = [None] * n_klaster
3     for each in range(len(k)):
4         avg_k[each] = [None] * len(k[each])
5         for each2 in range(len(k[each])):
6             avg_k[each][each2] = [None] * n_klaster
7     for i in range(n_klaster):
8         for x in range(len(k[i])):
9             for ii in range(n_klaster):
10                sum_k = []
11                for y in range(len(k[ii])):
12                    sum_d = []
13                    for z in range(len(k[i][x][0])):
14                        if i == ii and x == y:
15                            pass
16                        else:
17                            if k[i][x][0][z] == k[ii][y][0][z]:
18                                sum_d.append(0)
19                            else:
20                                sum_d.append(1)
21                    sum_k.append(sum(sum_d))
22                avg_k[i][x][ii] = sum(sum_k) / len(sum_k)
23     f = open('silhouette_coefficient.csv', 'w')
24     sfc = [None] * n_klaster
25     for i in range(len(avg_k)):
26         sfc[i] = []
27         for ii in range(len(avg_k[i])):
28             a = avg_k[i][ii].pop(i)
29             b = min(avg_k[i][ii])
30             sf = (b-a)/max(a,b)
31             sfc[i].append(float(sf))
32         f.write('{} , {} , {} \n'.format(i, ii, sf))
33     f.close()
34     sfc_c = []
35     for i in range(len(sfc)):
36         avg = sum(sfc[i]) / len(sfc[i])
37         sfc_c.append(avg)
38
39     sfc_all = []
40     for x in sfc:
41         for y in x:
42             sfc_all.append(y)
43     avg_sfc = sum(sfc_all) / len(sfc_all)
44     return sfc_c, avg_sfc
```

Kode Program 5.4 Proses Pengujian Klusterisasi

Penjelasan Kode Program 5.4 adalah sebagai berikut:

1. Baris 14 adalah untuk melakukan pemeriksaan bahwa dokumen yang sedang diuji tidak menghitung jarak dengan dokumen itu sendiri.
2. Baris 17-21 adalah proses penghitungan jarak antar dokumen baik dalam satu klaster maupun dengan anggota klaster yang lain.
3. Baris 22 adalah nilai rata-rata dari jarak suatu dokumen dengan dokumen lain pada suatu klaster.

4. Baris 25-32 adalah mengambil nilai untuk variabel a yaitu rata-rata jarak dari suatu dokumen dengan anggota lain pada kluster dokumen tersebut dan untuk variabel b yaitu nilai minimum dari rata-rata jarak suatu dokumen dengan anggota kluster lain. Dengan kedua variabel ini maka dapat dihitung nilai *Silhouette Coefficient* untuk setiap dokumen.
5. Baris 35-37 adalah untuk mengetahui nilai *Silhouette Coefficient* per kluster.
6. Baris 39-43 adalah untuk mengetahui nilai rata-rata *Silhouette Coefficient* secara keseluruhan.

5.3.3.3 Proses Klasterisasi Data Uji

Proses untuk mengetahui aspek suatu data uji dengan menempatkan data tersebut terlebih dahulu ke dalam kluster yang sesuai.

```

1 def get_aspek (inp, tipe, nama_dok = 0):
2     f = open('centroid.txt', 'r')
3     cntrd = f.read()
4     f.close()
5     centroid = cntrd.split('-')
6     f = open('aspek.txt', 'r')
7     aspck = f.read()
8     f.close()
9     aspek = aspck.split('\n')
10
11     list_bon_real = db.get_kata_nomina()
12     list_bon = []
13     list_data = db.get_data_latih()
14
15     for x in list_bon_real:
16         c = [x for dok in list_data if re.search(r'\b{}\b'.format(x),
17 dok.lower())]
18         if len(c) > 2:
19             list_bon.append(x)
20
21     vek_kata = []
22     for y in list_bon:
23         if re.search(r'\b{}\b'.format(y), inp.lower()):
24             vek_kata.append(1)
25         else:
26             vek_kata.append(0)
27     vek_dok = [vek_kata, str(nama_dok)]
28
29     n_klaster = len(centroid)
30
31
32
33     sum_x = [None] * n_klaster
34     for x in range(len(sum_x)):
35         sum_x[x] = []
36
37     hd = [None] * n_klaster
38     for indx in range(len(vek_dok[0])):
39         for indy in range(n_klaster):
40             if vek_dok[0][indx] == centroid[indy][indx] or
41 centroid[indy][indx] == 2:
42                 sum_x[indy].append(0)
43             else:
44                 sum_x[indy].append(1)
45     for indz in range(len(hd)):
46         hd[indz] = sum(sum_x[indz])

```

```

47 centroid_value = hd
48 closest = min(centroid_value)
49 result_cluster = centroid_value.index(closest)+1
50 return aspek[result_cluster]

```

Kode Program 5.5 Proses Klasterisasi Data Uji

Penjelasan Kode Program 5.5 adalah sebagai berikut:

1. Baris 2-9 adalah untuk mengambil nilai *centroid* dan aspek yang telah menjadi representasi dari suatu kluster.
2. Baris 15-27 adalah pembentukan vektor dokumen berdasarkan kemunculan kata pada dokumen tersebut.
3. Baris 33-47 adalah penghitungan jarak dokumen dengan setiap kluster.
4. Baris 48-49 adalah penentuan dokumen tersebut masuk ke kluster mana.
5. Baris 50 adalah untuk mengetahui aspek yang relevan terhadap dokumen tersebut.

5.3.4 Proses Hitung Skor Ulasan

Untuk melakukan ekstraksi fitur berupa skor ulasan, sebelumnya telah dilakukan proses preprocessing hingga didapat sekumpulan dokumen dengan kata-kata unik yang ada di dalamnya.

```

1 w = []
2 for x in range(len(list_t)):
3     term_doc = []
4     for y in list_t[x]:
5         if y:
6             term_occ = len(re.findall(r'\b{}\b'.format(y),
7 list_f2[x]))
8             term_doc.append(term_occ)
9         w.append(term_doc)
10
11 s_term_pos = []
12 s_term_neg = []
13 for x in range(len(list_t)):
14     term_doc_pos = []
15     term_doc_neg = []
16     for y in list_t[x]:
17         if y:
18             try:
19
20                 term_pos = len([y for dok in list_dok_positif if
21 re.search(r'\b{}\b'.format(y), dok.lower())])
22                 term_neg = len([y for dok in list_dok_negatif if
23 re.search(r'\b{}\b'.format(y), dok.lower())])
24                 if term_pos == 0 and term_neg == 0:
25                     print '{},{}'.format(y,x)
26
27                 term_doc_pos.append(term_pos/(term_pos+term_neg))
28                 term_doc_neg.append(term_neg/(term_pos+term_neg))
29             except Exception as e:
30                 print e
31         s_term_pos.append(term_doc_pos)
32         s_term_neg.append(term_doc_neg)
33
34 s_doc = []
35 f = open('score_representations.csv', 'w')

```

```

36 for x in range(len(w)):
37     s_doc_pos = 0
38     s_doc_neg = 0
39     for y in range(len(w[x])):
40         s_doc_pos += w[x][y] * s_term_pos[x][y]
41         s_doc_neg += w[x][y] * s_term_neg[x][y]
42     s_doc.append([s_doc_pos, s_doc_neg, list_kelas[x]])
43     if x == len(w)-1:
44         f.write('{} , {} , {}'.format(s_doc_pos, s_doc_neg,
45 list_kelas[x]))
46     else:
47         f.write('{} , {} , {} \n'.format(s_doc_pos, s_doc_neg,
48 list_kelas[x]))
49 f.close()

```

Kode Program 5.6 Proses Hitung Skor Ulasan

Penjelasan Kode Program 5.6 adalah sebagai berikut:

1. Baris 1-9 adalah untuk menghitung bobot kata pada setiap dokumen dengan melihat kepada jumlah kemunculannya.
2. Baris 20-25 adalah untuk mengetahui suatu kata terdapat di dalam berapa dokumen positif dan berapa dokumen negatif.
3. Baris 27-32 adalah pembentukan vektor skor kata positif dan negatif.
4. Baris 36-48 adalah penghitungan skor dokumen untuk positif dan negatif.

5.3.5 Proses Klasifikasi dengan LVQ

5.3.5.1 Proses Pelatihan dengan LVQ

Dari hasil merepresentasikan dokumen dalam bentuk skor kemudian dilakukan pelatihan dengan metode LVQ 2 hingga diambil bobot terakhir sebagai bobot ideal untuk klasifikasi.

```

1     alpha = 0.5
2     epsilon = 0.5
3     decalpha= 0.5
4     s_r_doc = open('score_representations.csv','r')
5     s_r = s_r_doc.read()
6     s_r_doc.close()
7
8     s = s_r.split('\n')
9     for x in range(len(s)):
10        s[x] = s[x].split(',')
11
12    for each in s:
13        if len(each) > 1:
14            if each[2] == 'positif':
15                each[2] = 1
16            elif each[2] == 'negatif':
17                each[2] = 2
18        else:
19            s.remove(each)
20    s_doc = [[float(y) for y in s[x]] for x in range(len(s))]
21    w0_pos = next((x for x in s_doc if x[2] == 1))
22    w0_neg = next((x for x in s_doc if x[2] == 2))
23    s_doc.remove(w0_pos)
24    s_doc.remove(w0_neg)

```

```

25
26     for epoch in range(maxepoch):
27         comp = []
28         d = []
29         match = 0
30         notmatch = 0
31         for indx in range(len(s_doc)):
32
33             d1 = math.sqrt(((float(s_doc[indx][0]) -
34 float(w0_pos[0]))**2)+((float(s_doc[indx][1])
35 float(w0_pos[1]))**2))
36             d2 = math.sqrt(((float(s_doc[indx][0]) -
37 float(w0_neg[0]))**2)+((float(s_doc[indx][1])
38 float(w0_neg[1]))**2))
39
40             min_d = min(d1,d2)
41             if min_d == d1:
42                 c = [1, d1]
43                 r = [2, d2]
44             elif min_d == d2:
45                 c = [2, d2]
46                 r = [1, d1]
47             d.append([indx,c[0],r[0]])
48             if d[indx][1] == s_doc[indx][2]:
49                 match+=1
50             elif d[indx][1] != s_doc[indx][2]:
51                 notmatch+=1
52
53             comp.append([s_doc[indx][2],c[0]])
54
55             if c[1]/r[1] > (1 - epsilon) and r[1]/c[1] < (1 +
56 epsilon):
57                 window = 1
58             else:
59                 window = 0
60
61             if window == 1 and r[0] == s_doc[indx][2]:
62                 if c[0] == 1:
63                     w0_pos[0] = w0_pos[0] - alpha *
64 (s_doc[indx][0] - w0_pos[0])
65                 elif r[0] == 1:
66                     w0_pos[0] = w0_pos[0] + alpha *
67 (s_doc[indx][0] - w0_pos[0])
68                 else:
69                     w0_pos[0] = w0_pos[0]
70             else:
71                 if c[0] == 1:
72                     if c[0] == s_doc[indx][2]:
73                         w0_pos[0] = w0_pos[0] + alpha *
74 (s_doc[indx][0] - w0_pos[0])
75                     else:
76                         w0_pos[0] = w0_pos[0] - alpha *
77 (s_doc[indx][0] - w0_pos[0])
78                 else:
79                     w0_pos[0] = w0_pos[0]
80
81
82             if window == 1 and r[0] == s_doc[indx][2]:
83                 if c[0] == 1:
84                     w0_pos[1] = w0_pos[1] - alpha *
85 (s_doc[indx][1] - w0_pos[1])
86                 elif r[0] == 1:
87                     w0_pos[1] = w0_pos[1] + alpha *
88 (s_doc[indx][1] - w0_pos[1])
89                 else:

```

```

90         w0_pos[1] = w0_pos[1]
91     else:
92         if c[0] == 1:
93             if c[0] == s_doc[indx][2]:
94                 w0_pos[1] = w0_pos[1] + alpha *
95 (s_doc[indx][1] - w0_pos[1])
96             else:
97                 w0_pos[1] = w0_pos[1] - alpha *
98 (s_doc[indx][1] - w0_pos[1])
99             else:
100                 w0_pos[1] = w0_pos[1]
101
102
103         if window == 1 and r[0] == s_doc[indx][2]:
104             if c[0] == 2:
105                 w0_neg[0] = w0_neg[0] - alpha *
106 (s_doc[indx][0] - w0_neg[0])
107             elif r[0] == 2:
108                 w0_neg[0] = w0_neg[0] + alpha *
109 (s_doc[indx][0] - w0_neg[0])
110             else:
111                 w0_neg[0] = w0_neg[0]
112         else:
113             if c[0] == 2:
114                 if c[0] == s_doc[indx][2]:
115                     w0_neg[0] = w0_neg[0] + alpha *
116 (s_doc[indx][0] - w0_neg[0])
117                 else:
118                     w0_neg[0] = w0_neg[0] - alpha *
119 (s_doc[indx][0] - w0_neg[0])
120             else:
121                 w0_neg[0] = w0_neg[0]
122
123
124         if window == 1 and r[0] == s_doc[indx][2]:
125             if c[0] == 2:
126                 w0_neg[1] = w0_neg[1] - alpha *
127 (s_doc[indx][1] - w0_neg[1])
128             elif r[0] == 2:
129                 w0_neg[1] = w0_neg[1] + alpha *
130 (s_doc[indx][1] - w0_neg[1])
131             else:
132                 w0_neg[1] = w0_neg[1]
133         else:
134             if c[0] == 2:
135                 if c[0] == s_doc[indx][2]:
136                     w0_neg[1] = w0_neg[1] + alpha *
137 (s_doc[indx][1] - w0_neg[1])
138                 else:
139                     w0_neg[1] = w0_neg[1] - alpha *
140 (s_doc[indx][1] - w0_neg[1])
141             else:
142                 w0_neg[1] = w0_neg[1]
143         alpha = alpha * decalpha
144
145

```

Kode Program 5.7 Proses Pelatihan dengan LVQ

Penjelasan Kode Program 5.7 adalah sebagai berikut:

1. Baris 21-22 adalah untuk inisialisasi bobot awal.
2. Baris 34-39 adalah penghitungan jarak antara bobot dengan masukan.

3. Baris 41-48 adalah penentuan kelas untuk masukan. Bernilai 1 berarti positif dan 2 berarti negatif.
4. Baris 56-60 adalah untuk mengetahui apakah masukan tersebut berada dalam *window* atau tidak.
5. Baris 62-102 adalah proses untuk melakukan pembaharuan terhadap bobot positif.
6. Baris 105-144 adalah proses untuk melakukan pembaharuan terhadap bobot negatif.

5.3.5.2 Proses Pengujian Klasifikasi

Untuk persiapan melakukan pengujian, telah dilakukan *filtering* untuk karakter selain alfabet untuk kemudian dilakukan pengujian.

```

1      d = []
2      comp = []
3      match = 0
4      notmatch = 0
5      for each in list_data_uji:
6          c, r = klasifikasi(each)
7          indx = list_data_uji.index(each)
8          t = list_kelas_uji[list_data_uji.index(each)]
9          if t == 'positif':
10             t = 1
11         elif t == 'negatif':
12             t = 2
13         d.append([indx,c,r])
14
15         if d[indx][1] == t:
16             match+=1
17         elif d[indx][1] != t:
18             notmatch+=1
19         comp.append([t,c])
20
21     pp = 0
22     pn = 0
23     np = 0
24     nn = 0
25     for each in comp:
26         if each[0] == 1:
27             if each[1] == 1:
28                 pp += 1
29             elif each[1] == 2:
30                 pn += 1
31         if each[0] == 2:
32             if each[1] == 1:
33                 np += 1
34             elif each[1] == 2:
35                 nn += 1
36
37     precision_pos = pp / (pp + np)
38     recall_pos = pp / (pp + pn)
39     fl_pos = 2 * precision_pos * recall_pos / (precision_pos +
40 recall_pos)
41     precision_neg = nn / (nn + np)
42     recall_neg = nn / (nn + pn)
43     fl_neg = 2 * precision_neg * recall_neg / (precision_neg +
44 recall_neg)

```

Kode Program 5.8 Proses Pengujian Klasifikasi

Penjelasan Kode Program 5.8 adalah sebagai berikut:

1. Baris 6 adalah untuk mengetahui hasil klasifikasi suatu masukan termasuk kelas mana.
2. Baris 15-18 adalah untuk melakukan pemeriksaan berapa hasil klasifikasi yang sesuai dengan *ground truth* dan berapa yang tidak sesuai.
3. Baris 25-35 adalah untuk pembentukan *confusion matrix* untuk positif dan negatif.
4. Baris 37-44 adalah untuk penghitungan *precision*, *recall*, dan *f1-score*.

5.3.5.3 Proses Klasifikasi

Proses ini adalah mengklasifikasikan suatu ulasan ke dalam kelas positif atau negatif.

```
1 def get_sentimen (inp):
2     inp = inp.lower()
3     for y in sw:
4         inp = re.sub(r'\b{}\b'.format(y), ' ', inp)
5     inp = re.sub('[^A-Za-z]+', ' ', inp)
6     inp2 = inp.split()
7     inp2 = list(set(inp2))
8     term_doc = []
9     for word in inp2:
10        if word:
11            term_occ = len(re.findall(r'\b{}\b'.format(word), inp))
12            term_doc.append(term_occ)
13        w = term_doc
14        term_doc_pos = []
15        term_doc_neg = []
16        for word in inp2:
17            if word:
18                try:
19                    term_pos = len([word for dok in
20 list_dok_positif if re.search(r'\b{}\b'.format(word), dok.lower())])
21                    term_neg = len([word for dok in
22 list_dok_negatif if re.search(r'\b{}\b'.format(word), dok.lower())])
23                    if term_pos == 0 and term_neg == 0:
24                        term_doc_pos.append(0)
25                        term_doc_neg.append(0)
26                    else:
27                        term_doc_pos.append(term_pos/(term_pos+term_neg))
28                        term_doc_neg.append(term_neg/(term_pos+term_neg))
29                except Exception as e:
30                    print e
31            s_term_pos = term_doc_pos
32            s_term_neg = term_doc_neg
33            s_doc_pos = 0
34            s_doc_neg = 0
35            for y in range(len(w)):
36                s_doc_pos += w[y] * s_term_pos[y]
37                s_doc_neg += w[y] * s_term_neg[y]
38            s_doc = [s_doc_pos, s_doc_neg]
39            s_doc = [float(y) for y in s_doc]
40            d1 = math.sqrt(((float(s_doc[0]) - float(w0_pos[0]))**2)+((float(s_doc[1]) - float(w0_pos[1]))**2))
41            d2 = math.sqrt(((float(s_doc[0]) - float(w0_pos[0]))**2)+((float(s_doc[1]) - float(w0_pos[1]))**2))
42            d3 = math.sqrt(((float(s_doc[0]) - float(w0_pos[0]))**2)+((float(s_doc[1]) - float(w0_pos[1]))**2))
43            d4 = math.sqrt(((float(s_doc[0]) - float(w0_pos[0]))**2)+((float(s_doc[1]) - float(w0_pos[1]))**2))
44            d5 = math.sqrt(((float(s_doc[0]) - float(w0_pos[0]))**2)+((float(s_doc[1]) - float(w0_pos[1]))**2))
45            d6 = math.sqrt(((float(s_doc[0]) - float(w0_pos[0]))**2)+((float(s_doc[1]) - float(w0_pos[1]))**2))
```

```

46         d2 = math.sqrt(((float(s_doc[0]) -
47 float(w0_neg[0]))**2)+((float(s_doc[1]) - float(w0_neg[1]))**2))
48
49         min_d = min(d1,d2)
50         if min_d == d1:
51             c = 1
52             r = 2
53         elif min_d == d2:
54             c = 2
55             r = 1
56         return c, r

```

Kode Program 5.9 Proses Klasifikasi

Penjelasan Kode Program 5.9 adalah sebagai berikut:

1. Baris 2-7 adalah untuk *pre-processing input*.
2. Baris 9-41 adalah untuk ekstraksi fitur *score representation*.
3. Baris 44-56 adalah untuk mendapatkan hasil klasifikasi sesuai metode LVQ

5.4 Implementasi Antarmuka

Gambar 5.4 menunjukkan hasil klusterisasi dengan menampilkan empat dokumen pada setiap kluster.

```

IPython console
Console 1/A
Hasil akhir:
Klaster 1 - Aspek: kamar-jam-makanan
36. Ketika kita pesan kamar melalui online (baik itu agoda, traveloka, mister aladin, dll) mes...
91. Saya booking harris untuk Tamu saya tanggal 2 Oktober 2016.saya kecewa dengan karyawan And...
105. kamar kurang kedap suara. drainase wastafel buruk. suasana ok. lemari pendingin di kamar t...
<><><><><>
Klaster 2 - Aspek: hotel-makanan-pelayanan
59. Lokadi Harris Malang sangat strategis dan menyenangkan untuk family trip. Sangat disayangk...
66. Pelayanan sangat mengecewakan terlalu mensegmentasikan pelanggan,antara pelanggan yang ter...
162. hotel harris di malang swimming poolnya baguss bangeett... cuma, pelayanan karyawan biasa ...
<><><><><>
Klaster 3 - Aspek: hotel-kamar-jam
101. saya dan keluarga menginap dr tgl 15 s.d 18 september 2016.. Pada hari pertama dan ke dua ...
108. hotel ini pada dasarnya bagus tapi yang tidak nyaman adalah pada malam tgl 10/9/2016 saya ...
112. Not friendly.. Saya state ini karena waktu saya menyuruh keponakan saya manggil waiters di...
<><><><><>
Klaster 4 - Aspek: hotel-anak-kolam
92. Sesampainya di hotel harris malang.tidak ada satupun karyawan yg menyambut kedatangan dan ...
207. Kantor mengadakan office gathering di hotel ini,acara berlangsung di taman sebelah kolam r...
230. Dear CS Fasilitas baik Permainan di kolam renang anak perlu diperbaiki Sambungan di

```

Gambar 5.4 Antarmuka Hasil Klusterisasi

Gambar 5.5 menunjukkan hasil pengujian klusterisasi dengan menampilkan nilai rata-rata *Silhouette Coefficient* pada setiap kluster kemudian rata-rata secara keseluruhan.

```

IPython console
Console 1/A
=====
Silhoutte Coefficient K1 = 0.162906338816
Silhoutte Coefficient K2 = 0.208390082378
Silhoutte Coefficient K3 = -0.0203141089467
Silhoutte Coefficient K4 = 0.154266309828
Silhoutte Coefficient K5 = 0.147471408019
Silhoutte Coefficient K6 = 0.285819299396
Silhoutte Coefficient K7 = 0.185293028695
Silhoutte Coefficient ALL = 0.119231899827

```

Gambar 5.5 Antarmuka Hasil Pengujian Klasterisasi

Gambar 5.6 menunjukkan hasil pengujian klasifikasi dengan menampilkan nilai *precision*, *recall*, dan *f1-score* untuk setiap kelas positif dan negatif kemudian rata-ratanya.

```

Learning rate: 0.5
Epsilon: 0.5
Pengurangan learning rate: 0.5
Max Epoch: 100
+-----+-----+-----+
|          | Precision | Recall  | F1      |
+-----+-----+-----+
| +        | 0.875    | 0.913043478261 | 0.893617021277 |
| -        | 0.909090909091 | 0.869565217391 | 0.888888888889 |
| Average | 0.892045454545 | 0.891304347826 | 0.891252955083 |
+-----+-----+-----+

```

Gambar 5.6 Antarmuka Hasil Pengujian Klasifikasi

Gambar 5.7 menunjukkan hasil pengujian pada satu data untuk aspek dan kelas sentimennya.

```

IPython console
Console 1/A
In [63]: ulasan = "Kami tiba di kami harus menunggu 3pm dan tentang satu jam untuk memeriksa ke dalam kamar. Mereka berkata bahwa kamar kami belum siap. Sementara itu, anak-anak saya sudah lelah dan ingin beristirahat untuk sementara waktu"
In [64]: show_get_aspek(ulasan, 'A')
Aspek (3 kata representasi klaster): hotel-makanan-pelayanan
In [65]: show_get_sentimen(ulasan)
Kelas: Negatif

```

Gambar 5.7 Antarmuka Uji Data