

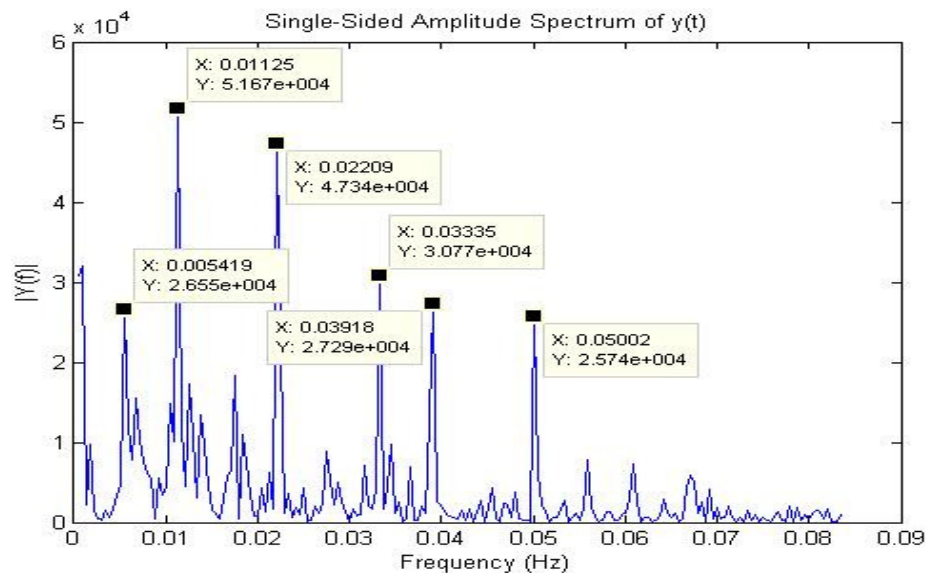
BAB 4

PENGOLAHAN DATA DAN ANALISIS

4.1 Analisis Variasi Berat Kertas dengan *Frequency Analysis*

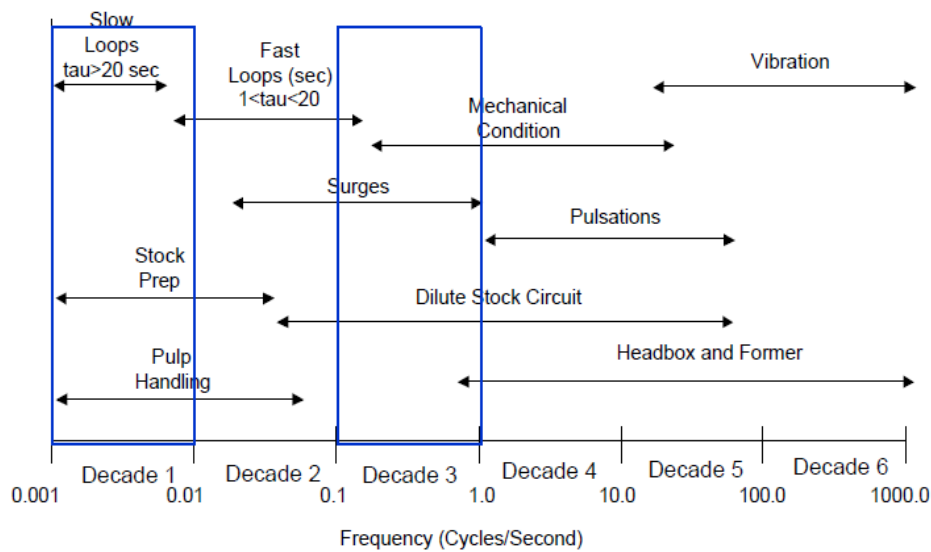
Frequency Analysis dilakukan untuk mengidentifikasi apakah ada pola-pola yang berulang secara periodik pada set data yang dianalisis. Analisis ini dilakukan terhadap variabel DW01_Control.

Hasil analisis menunjukkan bahwa variasi MD terjadi secara periodik dengan frekuensi pengulangan antara 0.01 – 0.1 Hz (Decade 2) atau antara 10 detik sampai 100 detik seperti tampak pada gambar 4.1.



Gambar 4.1 Spektrum Variabel DW01_Control

Sumber variasi ini adalah proses di bagian *stock preparation* yang sebagian besar masih dilakukan dengan sistem *batch* seperti proses pembuburan *pulp* dan proses pengisian tangki penyangga (*buffer tank*) untuk bahan. Sumber-sumber variasi lainnya untuk berbagai rentang frekuensi dapat dilihat pada gambar 4.2 di bawah ini.



Gambar 4.2 Penyebab Variasi pada Berbagai Rentang Frekuensi
(sumber: *Subramani.*, n.d)

Variasi yang terjadi pada frekuensi di bawah 0.1 Hz masih dapat dikoreksi oleh peralatan QCS. Dalam hal ini peralatan QCS perlu ditala (*tune*) lagi agar mampu merespon perubahan proses secara akurat.

4.2 Analisis Kestabilan Proses dengan PCA

PCA merupakan teknik yang luas digunakan untuk mengekstrak variasi sistematis dan hubungan antar variabel dari suatu data set. Tujuannya adalah untuk mengurangi dimensi variabel suatu data set dan untuk interpretasi data Hasil transformasi PCA terhadap variabel proses yang disebutkan dalam bab tiga menghasilkan beberapa PC seperti tampak pada tabel 4.1 berikut ini.

Tabel 4.1. Hasil Analisa PCA

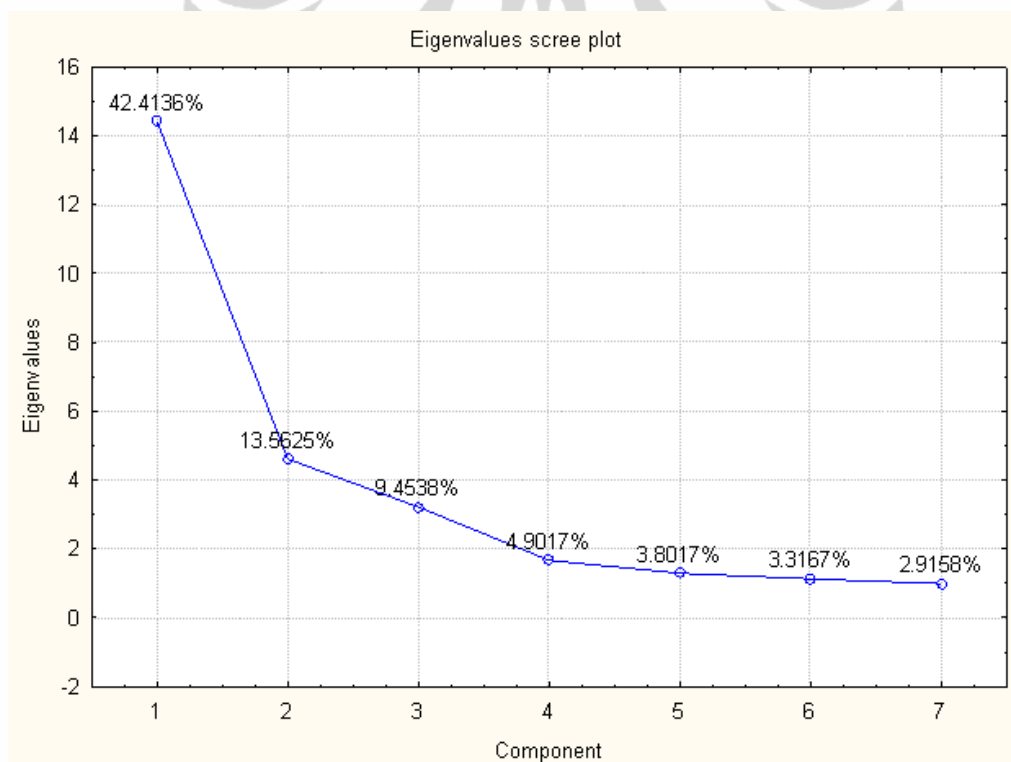
Component	R ² X	R ² X (Cumul.)	Eigenvalues	Q ²	Limit	Q ² (Cumul.)
1	0.424136	0.424136	14.42063	0.399862	0.029601	0.399862
2	0.135625	0.559761	4.61125	0.180461	0.030492	0.508164
3	0.094538	0.654300	3.21431	0.182055	0.031439	0.597705
4	0.049017	0.703317	1.66658	0.042910	0.032447	0.614967
5	0.038017	0.741334	1.29258	0.013107	0.033522	0.620014
6	0.033167	0.774500	1.12767	-0.048369	0.034672	0.601634
7	0.029158	0.803659	0.99138	-0.060746	0.035903	0.577435

Dari tabel di atas dapat dilihat bahwa 80.36% variasi pada variabel proses terwakili oleh 7 komponen dimana komponen pertama (PC1) menjelaskan 42,41% variasi pada variabel proses, PC2 menjelaskan 13.56% variasi, PC3 menjelaskan 9.45% variasi dan seterusnya. PC1 adalah merupakan komponen yang paling signifikan dibandingkan PC lainnya.

Jumlah PC menentukan kompleksitas dan akurasi model. Semakin banyak jumlah PC, akurasi model menjadi semakin baik namun model menjadi semakin kompleks. Tujuannya adalah untuk mendapatkan model yang tidak terlalu kompleks namun cukup akurat untuk memprediksi data.

Untuk menentukan jumlah PC digunakan metode *scree test* yang diusulkan oleh cattell (1966) dimana jumlah PC ditentukan berdasarkan titik terendah dari slope *Eigenvalues*.


Eigenvalue dapat diinterpretasikan sebagai proporsi dari varian. Dari Grafik *Eigenvalue Scree Plot* gambar 4.4 tampak bahwa titik terendah adalah komponen kelima sehingga dipilih jumlah PC dari model adalah lima.



Gambar 4.3 *Eigenvalue Scree Plot*


Dari grafik tersebut juga dapat dilihat bahwa komponen keenam dan ketujuh nilainya cukup kecil sehingga model PCA dengan 5 komponen ini cukup signifikan untuk mewakili variasi pada set data variabel proses

Sebagai pembandingan digunakan satu metode lainnya untuk menentukan jumlah PC yang optimal yaitu menggunakan nilai Q^2 . Nilai Q^2 adalah nilai prediksi yang dihitung menggunakan sampel dari data observasi. Tidak seperti nilai R^2X yang selalu bertambah besar dengan bertambahnya komponen, nilai Q^2 akan mencapai batas maksimum pada titik tertentu yang kemudian nilainya akan turun dengan bertambahnya komponen seperti ditunjukkan pada gambar 4.3. Titik dimana nilai Q^2 mulai turun dijadikan patokan untuk menentukan jumlah PC yang optimal, yaitu pada komponen ke lima. Dengan demikian, kedua metode ini menghasilkan nilai yang sama untuk jumlah komponen PC.



Gambar 4.4 Histogram Nilai R^2X dan Q^2

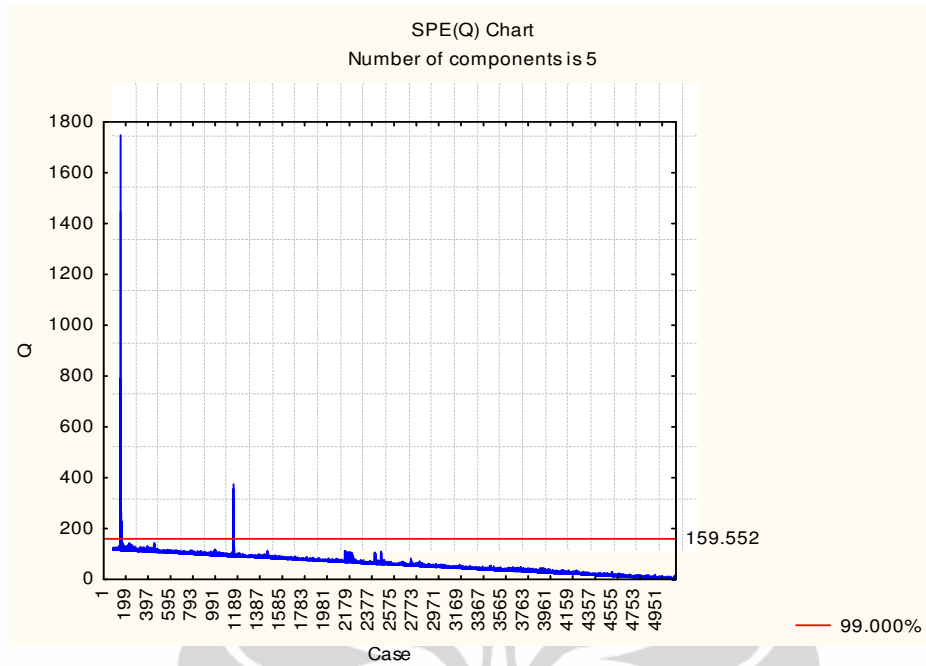
Setelah model PCA terbentuk langkah selanjutnya adalah menggunakan model ini untuk menganalisis kestabilan proses dengan menggunakan peta kendali (*control chart*) yang dinamakan *Hottelling T² Control Chart*. Peta kendali untuk data proses yang diamati tampak seperti gambar 4.5 di bawah ini.



Gambar 4.5 Peta Kendali *Hotelling T^2*


Dari grafik peta kendali di atas tampak beberapa data berada di luar batas kendali (*outliers*) antara lain kasus ke 1 – 45, 71 – 128, dan ke 1078 – 1082. Dengan kata lain bahwa proses terdeteksi *ubnormal* pada rentang waktu tersebut.

Sebagai pembandingan digunakan peta kendali lainnya yang diusulkan oleh MacGregor & T Kourti (1996) yaitu peta kendali *Square of Prediction Error* (SPE(Q)), seperti tampak pada gambar 4.6. Ternyata data *outliers* yang ditunjukkan oleh peta kendali SPE(Q) sedikit berbeda dengan sebelumnya dimana *outliers* terjadi pada kasus ke 71 – 75 dan ke 1078 – 1081.



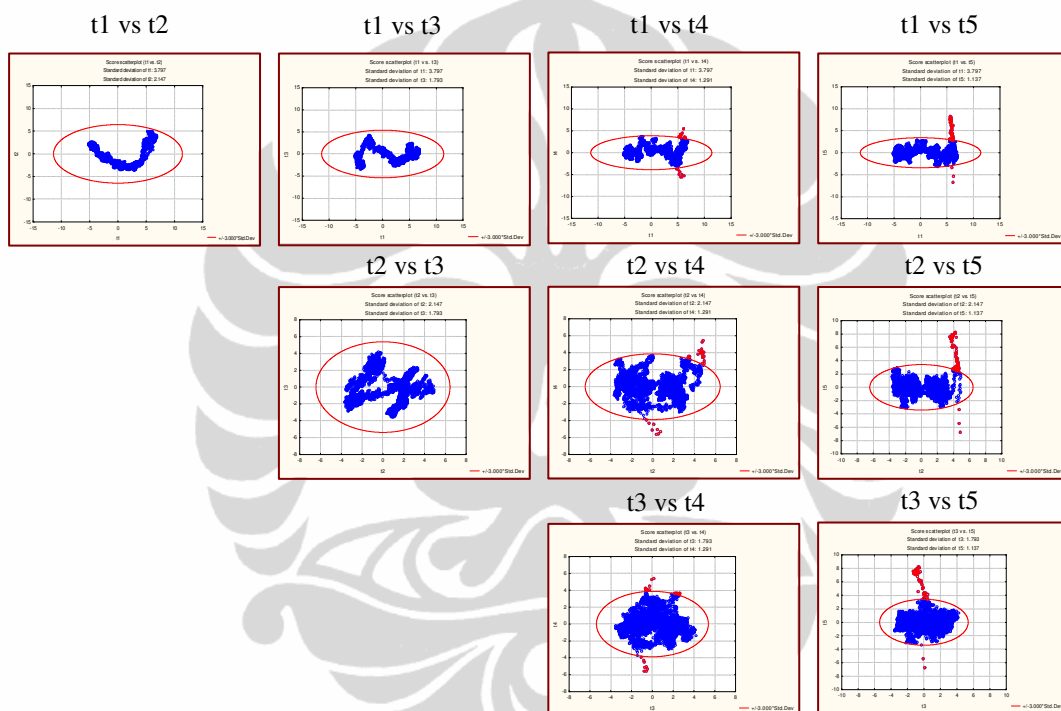
Gambar 4.6 Peta Kendali SPE (Q)

Untuk menjelaskan data *outliers* maka digunakan satu lagi metode yaitu menghitung jarak residual terhadap model (*Distance-to-Model*). Hasil analisis ini ditunjukkan oleh gambar 4.7 di bawah ini.

Gambar 4.7 Grafik *D-to-Model*

Dari kedua grafik terlihat bahwa *SPE Chart* dan *T-to-Model Chart* menghasilkan data *ouliers* yang sama. *Ouliers* terjadi pada kasus ke 71 – 75 dan ke 1078 – 1081. Dalam hal ini, peta kendali *Hotelling T²* tidak cukup akurat untuk kasus ini.

Untuk mengetahui komponen yang berkontribusi pada terjadinya *ouliers* dilakukan dengan membuat *scatter plot* untuk masing-masing *x-score* komponen PCA seperti tampak pada gambar 4.8 di bawah ini



Gambar 4.8 *Score Scatter Plot*

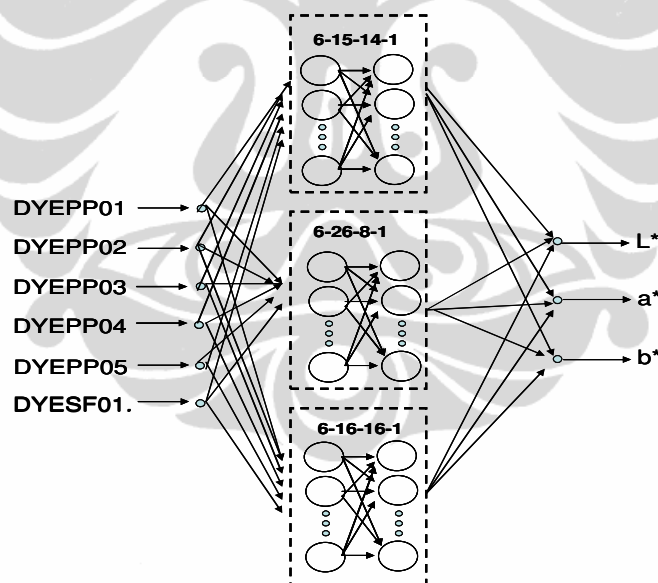
Dari grafik *score scatter plot* di atas tampak bahwa *ouliers* terjadi pada score ke-4 (*t4*) dan score ke-5 (*t5*). Jika dilihat dari kasusnya, *outlier* terjadi kurang dari 1 menit karena hanya ada empat atau lima data saja yang jatuh di luar batas kendali sedangkan data yang ditarik oleh peralatan QCS adalah 11 data per menit. Dengan demikian disimpulkan bahwa selama pemantauan proses berjalan stabil.

4.3 Analisis properti warna berdasarkan model *Neural Network*

Model *Neural Network* (NN) digunakan untuk mensimulasikan proses pewarnaan kertas. Berdasarkan model ini selanjutnya dianalisis pola interaksi antar bahan pewarna dan efeknya pada properti warna L^* a^* b^* menggunakan analisis faktorial. Kelebihan menggunakan model NN dibandingkan dengan eksperimen yang dilakukan di lab antara lain bahwa model ini lebih mendekati kondisi sistem yang sesungguhnya.

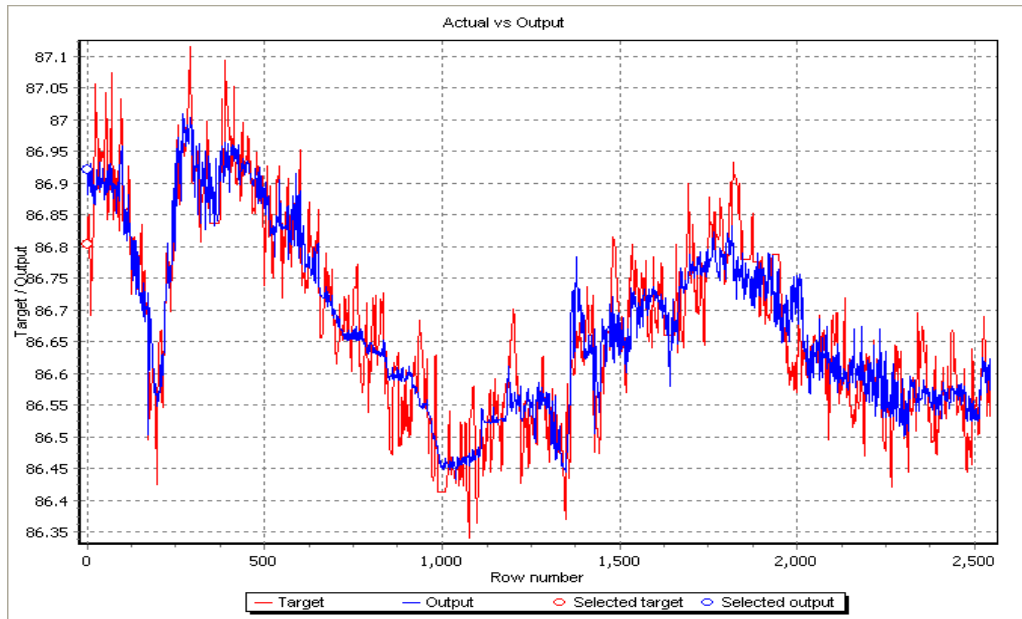
Untuk membangun model NN diperlukan data histori dari proses *input* dan proses *output*. Selanjutnya data-data tersebut dipartisi menjadi 3 bagian yaitu 70% untuk *training*, 15% untuk validasi dan 15% untuk *test*.

Arsitektur jaringan yang dibuat terdiri dari 1 *input layer*, 2 *hidden layer* dan 1 *output layer*, seperti tampak pada gambar 4.9. Masing-masing *hidden layer* menggunakan fungsi aritmatika *log-sigmoid* dan fungsi *linier*.




Gambar 4.9 Arsitektur jaringan NN


Perbandingan *output* model NN dengan *output* sesungguhnya (target) untuk variabel L^* a^* b^* , dapat dilihat pada gambar 4.10, 4.11 dan 4.12 di bawah ini.



Gambar 4.10 Perbandingan *Output* Model NN dengan Target untuk Variabel L*



Gambar 4.11 Perbandingan *Output* Model NN dengan Target untuk Variabel a*



Gambar 4.12 Perbandingan *Output* Model NN dengan Target untuk Variabel b^*

Dari ketiga gambar tersebut tampak bahwa *output* model NN mendekati *output* sesungguhnya (target). Korelasi antara *output* model NN dengan target tampak pada tabel 4.2 di bawah ini

Tabel 4.2. Korelasi output Jaringan NN terhadap Target

Variabel	Data	Nilai Target rata-rata	Nilai Output rata-rata	Korelasi	<i>R-squared</i>
L^*	Training	86.682972	86.682756	0.9207	0.8189
	Test	86.672023	86.674685	0.9079	0.8243
	Validasi	86.670818	86.673410	0.9058	0.8205
a^*	Training	-10.396104	-10.393623	0.9728	0.9428
	Test	-10.404272	-10.403196	0.9659	0.9290
	Validasi	-10.404248	-10404826	0.9691	0.9349
b^*	Training	70.259106	70.259478	0.8444	0.5880
	Test	70.264259	70.266903	0.7909	0.6244
	Validasi	70.263869	70.256892	0.8210	0.6740

Dari tabel di atas dapat dilihat bahwa korelasi antara nilai keluaran prediksi jaringan NN dengan nilai keluaran sesungguhnya sangat kuat. Ini menunjukkan adanya kedekatan model NN dengan sistem yang sesungguhnya.

Berdasarkan hasil di atas maka model NN selanjutnya digunakan untuk menganalisis pola interaksi antara variabel input dan variabel output dengan menggunakan analisis faktorial. Dalam hal ini akan disimulasikan 6 faktor masukan masing-masing dengan 2 level seperti tampak pada tabel 4.5 di bawah ini.

Tabel 4.3 Desain Faktorial: 6 Faktor – 2 level

Faktor	Level	
	L	H
DYEPP01 (A)	10	35
DYEPP02 (B)	5	55
DYEPP03 (C)	10	21
DYEPP04 (D)	0	50
DYEPP05 (E)	0	80
DYESF01 (F)	80	88

Dengan 6 faktor maka diperoleh 64 kombinasi masukan dari “LLLLLL” sampai “HHHHHH”. Kombinasi masukan ini selanjutnya dijalankan pada model NN diperoleh hasil seperti tampak pada tabel 4.4.

Analisis faktorial ini hanya menggunakan satu replikasi karena model NN akan menghasilkan keluaran yang sama untuk kombinasi masukan yang sama. Menurut Montgomery (2005) dengan hanya menggunakan satu replikasi maka tidak ada estimasi *error* internal.

Satu pendekatan untuk menganalisis faktorial tanpa replikasi adalah dengan mengabaikan interaksi-interaksi order tinggi dan mengkombinasikan rata-rata kuadrat (*mean squares*) untuk mengestimasi error. Menurut prinsip efek order rendah, kebanyakan interaksi order tinggi diabaikan

Ketika menganalisis faktorial tanpa replikasi, kadang-kadang interaksi order tinggi benar-benar terjadi. Menurut Daniel (1959), efek yang diabaikan


Tabel 4.4 Output model NN dengan kombinasi 6 faktor masukan

N	DYEP01	DYEP02	DYEP03	DYEP04	DYEP05	DYEF01	L*	a*	b*
1	10	5	10	0	0	80	83.313197	-11.15483	69.299271
2	10	5	10	50	80	88	79.90376	-10.80731	48.912831
3	10	5	10	50	0	88	79.970404	-10.88437	48.571161
4	10	5	10	0	80	80	83.482543	-10.75576	70.517773
5	10	5	10	50	0	80	80.416114	-11.04361	48.907162
6	10	5	10	0	0	88	87.494742	-11.26418	55.815349
7	10	5	10	0	80	88	80.26284	-10.73346	57.017511
8	10	5	10	50	80	80	80.236882	-11.02352	55.663081
9	10	5	21	50	80	88	81.35995	-10.92719	56.620607
10	10	5	21	50	0	88	81.441519	-11.09603	56.124586
11	10	5	21	0	80	80	71.908116	-11.07687	67.19783
12	10	5	21	0	80	88	87.207469	-11.32163	63.318085
13	10	5	21	50	80	80	81.000025	-11.18915	56.557858
14	10	5	21	50	0	80	81.147324	-11.18974	55.279705
15	10	5	21	0	0	80	76.576999	-10.85384	68.974487
16	10	5	21	0	0	88	84.433787	-10.70578	56.978351
17	10	55	10	0	0	88	75.848124	-12.0532	57.742669
18	10	55	10	50	80	88	74.884887	-11.19601	48.714948
19	10	55	10	0	80	80	73.915896	-11.66215	70.54014
20	10	55	10	50	0	80	80.285134	-11.80517	49.405995
21	10	55	10	0	80	88	75.802976	-11.58945	59.930676
22	10	55	10	50	0	88	80.161413	-11.66079	48.655211
23	10	55	10	0	0	80	80.965203	-12.36041	69.296672
24	10	55	10	50	80	80	73.519857	-11.50213	53.582189
25	10	55	21	50	80	88	76.104636	-10.72478	56.675462
26	10	55	21	50	0	80	73.830412	-11.68557	55.688524
27	10	55	21	0	80	88	85.786612	-10.88858	64.035261
28	10	55	21	0	0	88	81.051904	-11.45728	57.449359
29	10	55	21	50	80	80	73.722231	-11.68293	57.294482
30	10	55	21	0	80	80	74.064276	-11.68159	68.796075
31	10	55	21	50	0	88	74.529296	-11.40261	56.295888
32	10	55	21	0	0	80	74.390544	-11.68277	65.87781
33	35	5	10	50	80	80	86.483373	-11.48719	63.028655
34	35	5	10	0	80	88	86.685478	-11.39063	70.853897
35	35	5	10	50	80	88	86.461664	-11.26593	70.493288
36	35	5	10	0	0	80	86.358974	-11.5072	63.205235
37	35	5	10	0	80	80	86.276591	-11.44006	63.384328
38	35	5	10	0	0	88	86.792304	-11.4586	70.554142
39	35	5	10	50	0	80	86.649725	-11.55506	63.106335
40	35	5	10	50	0	88	86.589708	-11.33847	70.013262
41	35	5	21	0	0	88	86.986372	-11.44494	70.74893
42	35	5	21	0	80	88	85.311378	-11.12487	70.955301
43	35	5	21	0	80	80	86.600541	-11.29661	70.071827
44	35	5	21	50	0	80	86.841425	-11.56928	69.195458
45	35	5	21	50	80	80	86.682496	-11.28115	70.122235
46	35	5	21	50	0	88	87.238884	-11.37162	68.699355
47	35	5	21	0	0	80	86.660838	-11.57427	69.843232
48	35	5	21	50	80	88	87.06701	-11.02093	69.965759
49	35	55	10	0	80	88	86.650531	-9.920942	71.238121
50	35	55	10	0	0	80	86.32737	-10.5479	64.896256
51	35	55	10	50	80	88	86.374664	-10.68804	68.647804
52	35	55	10	0	0	88	86.716731	-10.01014	71.002064
53	35	55	10	50	80	80	86.36332	-10.89276	63.088864
54	35	55	10	0	80	80	86.262053	-10.08149	65.926741
55	35	55	10	50	0	88	86.493966	-10.76624	68.365984
56	35	55	10	50	0	80	86.444099	-11.25826	61.155685
57	35	55	21	50	80	88	86.862791	-10.89285	68.247758
58	35	55	21	0	80	88	85.964234	-10.31996	71.159851
59	35	55	21	50	80	80	86.550412	-11.13592	68.538561
60	35	55	21	0	0	80	86.116939	-10.4988	70.491987
61	35	55	21	0	0	88	86.054281	-10.25023	70.613682
62	35	55	21	50	0	80	86.638884	-11.16621	68.224965
63	35	55	21	50	0	88	86.998969	-10.96564	68.410959
64	35	55	21	0	80	80	86.150658	-10.88958	70.607598

terdistribusi secara normal dengan rata-rata nol dan varian σ^2 dan cenderung terjadi di sepanjang garis lurus pada *normal probability plot*. Efek yang signifikan akan mempunyai rata-rata bukan nol (*nonzero means*) dan terjadi jauh dari garis tersebut (Montgomery,2005)

4.3.1 Efek bahan pewarna terhadap properti warna L*

Efek bahan pewarna terhadap variabel L* dapat dilihat pada *normal probability plot* gambar 4.13 berikut ini.




Gambar 4.13 Normal Probability Plot untuk Properti Warna L*

Dari *normal probability plot* tampak bahwa faktor A, B dan F mempunyai efek yang signifikan terhadap variabel L*. Faktor A dan F mempunyai efek positif sedangkan faktor B mempunyai efek negatif. Efek masing-masing faktor terhadap variabel L* dapat dilihat pada diagram Pareto di bawah ini.

Dari gambar 4.15 terlihat bahwa faktor A, B dan C tidak saling berinteraksi sedangkan faktor C dan F saling berinteraksi. Dari gambar tersebut dapat dilihat untuk nilai C rendah kenaikan faktor F tidak berpengaruh pada nilai L^* . Sebaliknya jika C tinggi kenaikan F akan menaikkan nilai L^* .


4.3.2 Efek bahan pewarna terhadap properti warna a^*

Efek bahan pewarna terhadap variabel L^* dapat dilihat pada *normal probability plot* gambar 4.16 berikut ini.



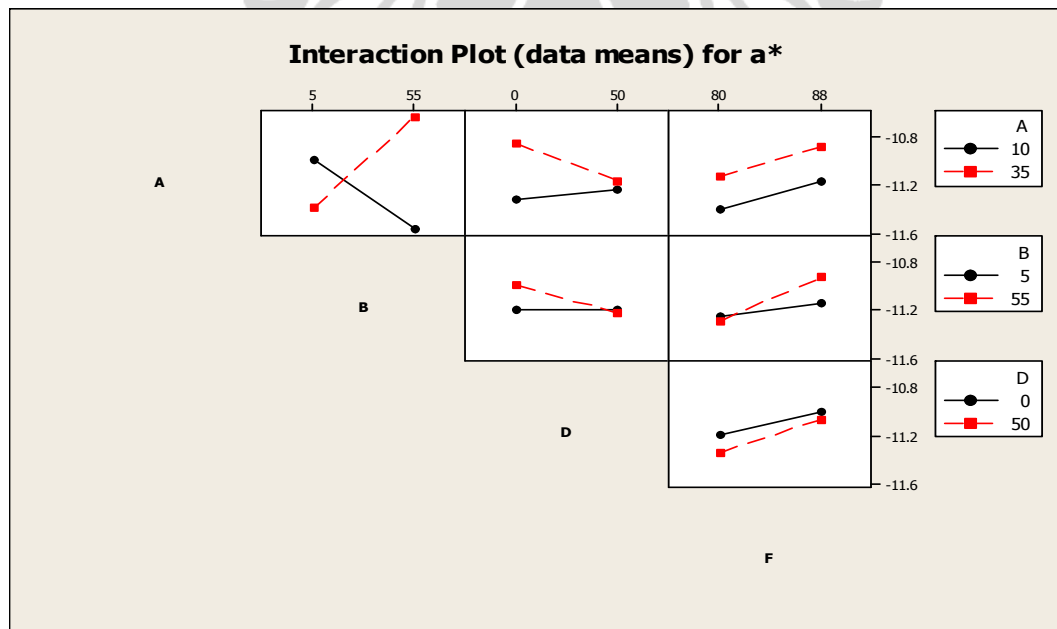
Gambar 4.16 Normal Probability Plot untuk Properti Warna a^*

Dari Gambar 4.16 tampak bahwa efek signifikan ditunjukkan oleh faktor A, E dan F. Ketiga faktor mempunyai efek positif terhadap properti warna a^* . Efek masing-masing faktor terhadap variabel a^* dapat dilihat pada diagram Pareto di bawah ini.



Gambar 4.17 Diagram Pareto Efek Bahan Pewarna terhadap Properti Warna a*

Dari diagram Pareto di atas tampak bahwa faktor AB, AD dan BF mempunyai efek yang signifikan terhadap properti warna a*. Interaksi antar faktor tersebut dapat dilihat pada Plot interaksi berikut ini.




Gambar 4.18 Plot Interaksi Bahan Pewarna terhadap Properti Warna a*

Dari Gambar 4.15 tampak bahwa faktor A dan B saling berinteraksi. Untuk nilai A yang rendah, kenaikan nilai B akan menurunkan nilai a^* . Sebaliknya jika nilai A tinggi, kenaikan nilai B akan menaikkan nilai a^* .


4.3.3 Efek bahan pewarna terhadap properti warna b^*

Efek bahan pewarna terhadap variabel L^* dapat dilihat pada *normal probability plot* gambar 4.19 berikut ini



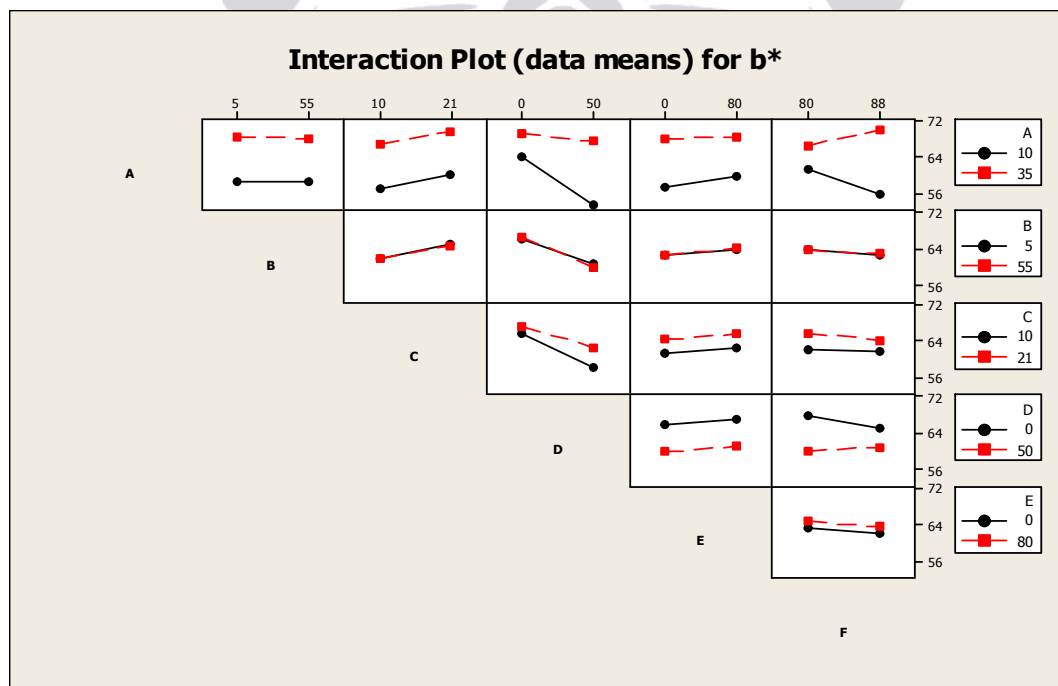
Gambar 4.19 Normal Probability Plot untuk Properti Warna b^*

Dari gambar 4.19 tampak bahwa faktor A, C, D, E dan F mempunyai efek yang signifikan terhadap variabel b^* . Faktor A, C dan E mempunyai efek positif sedangkan faktor F dan D mempunyai efek negative seperti tampak pada gambar 4.20 di bawah ini.



Gambar 4.20 Plot Efek Utama Bahan Pewarna terhadap Properti Warna b*

Interaksi antar faktor dapat dilihat pada plot interaksi gambar 4.21 di bawah ini. Tampak dari gambar tersebut masing-masing faktor tidak saling berinteraksi.



Gambar 4.21 Plot Interaksi Bahan Pewarna terhadap Properti Warna b*

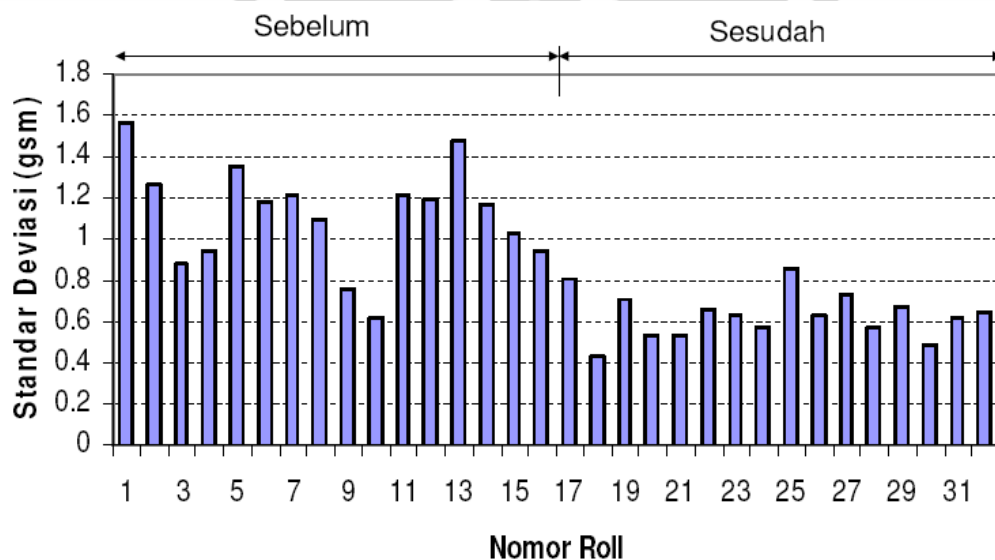
Dari penjelasan di atas dapat disimpulkan bahwa variabel DYEPP01, DYEPP02 dan DYESF01 mempunyai efek yang signifikan terhadap properti warna L*. Faktor yang mempunyai pengaruh signifikan pada properti warna a* adalah variabel DYEPP01, DYEPP05 dan DYESF01. Adapun yang berpengaruh pada properti warna b* adalah variabel DYEPP01, DYEPP03, DYEPP04, DYEPP05 dan DYESF01.

Semakin banyak variabel yang berinteraksi semakin besar kemungkinannya terjadi variasi. Dalam hal ini ada 5 variabel yang mempunyai efek signifikan terhadap properti warna b*.


4.4 Usulan Perbaikan

Dari penelitian yang sudah dilakukan diperoleh hasil bahwa variasi yang terjadi pada kualitas produk lebih dominan terjadi pada arah melintang (*Cross Direction*) dimana pada arah ini pengendalian proses dilakukan dengan mengatur bukaan mulut *slice* (*slice lip*) secara manual sehingga sangat bergantung pada skill operator.

Hasil pengaturan kembali bukaan mulut *slice* yang dilakukan selama penelitian menunjukkan adanya perbaikan pada 2-sigma profil berat kertas seperti tampak pada gambar 4.22 dan 4.23 di bawah ini.



Gambar 4.22 Standar Deviasi Profil BW Sebelum dan Sesudah Perbaikan



Gambar 4.23 Profil BW Sebelum dan Sesudah Perbaikan

Standar deviasi rata-rata untuk 16 roll kertas sebelum dilakukan perbaikan adalah 1.12 untuk berat 60.5 gsm dan setelah dilakukan perbaikan standar deviasi turun menjadi 0.63 atau terjadi perbaikan sebesar **43.64%**.

Berdasarkan hasil penelitian yang di atas, maka dapat diusulkan beberapa saran perbaikan sebagai berikut:

1. Pengendalian CD profile ini masih dilakukan secara manual yaitu oleh operator. Untuk meningkatkan mutu kertas maka perlu dipasang sistem kontrol yang dapat mengatur bukaan mulut *slice headbox* secara otomatis.
2. Perlunya dilakukan *tuning* dan kalibrasi secara rutin alat-alat QCS agar dapat mereduksi variasi yang terjadi di dalam proses.
3. Pemilihan bahan pewarna (dyes) perlu memperhatikan efek interaksi terhadap variabel warna. Semakin banyak variabel yang berinteraksi semakin besar kemungkinannya terjadi variasi.