

# MODEL JARINGAN SYARAF TIRUAN UNTUK MEMPREDIKSI PARAMETER KUALITAS TOMAT BERDASARKAN PARAMETER WARNA RGB

An Artificial Neural Network Model for Predicting Tomato Quality Parameters Based on Color

Rudiati Evi Masithoh<sup>1</sup>, Budi Rahardjo<sup>1</sup>, Lilik Sutiarso<sup>1</sup>, Agus Hardjoko<sup>2</sup>

<sup>1</sup>Jurusan Teknik Pertanian, Fakultas Teknologi Pertanian, Universitas Gadjah Mada, Jl. Flora No 1, Bulaksumur, Yogyakarta 55281.

<sup>2</sup>Program Studi Elektronika dan Instrumentasi, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Gadjah Mada,

Jl. Kaliurang Km. 5,5, Sekip Utara, Yogyakarta 55281.

Email: evi@gadjahmada.edu

## ABSTRAK

Jaringan syaraf tiruan (JST) digunakan untuk memprediksi parameter kualitas tomat, yaitu Brix, asam sitrat, karoten total, dan vitamin C. JST dikembangkan dari data Red Green Blue (RGB) citra tomat yang diukur menggunakan *computer vision system*. Data kualitas tomat diperoleh dari analisis di laboratorium. Struktur model JST didasarkan pada jaringan *feedforward backpropagation* dengan berbagai fungsi pelatihan, yaitu gradient descent (*traingd*), gradient descent dengan resilient backpropagation (*trainrp*), Broyden, Fletcher, Goldfrab dan Shanno (BFGS) quasi-Newton (*trainbfg*), serta Levenberg Marquardt (*trainlm*). Fungsi pelatihan yang terbaik adalah menggunakan *trainlm*, serta pada struktur jaringan digunakan fungsi aktivasi logsig pada lapisan tersembunyi dan linier (*purelin*) pada lapisan keluaran. dengan 1000 epoch. Nilai koefisien korelasi ( $r$ ) pada tahap pelatihan dan validasi secara berturut-turut adalah 0.97 - 0.99 dan 0.92 - 0.99; sedangkan nilai MAE berkisar antara 0.01-0.23 dan 0.03-0.59.

**Kata kunci:** Jaringan syaraf tiruan, *trainlm*, tomat, RGB

## ABSTRACT

Artificial neural networks (ANN) was used to predict the quality parameters of tomato, i.e. Brix, citric acid, total carotene, and vitamin C. ANN was developed from Red Green Blue (RGB) image data of tomatoes measured using a developed computer vision system (CVS). Qualitative analysis of tomato compositions were obtained from laboratory experiments. ANN model was based on a feedforward backpropagation network with different training functions, namely gradient descent (*traingd*), gradient descent with the resilient backpropagation (*trainrp*), Broyden, Fletcher, Goldfrab and Shanno (BFGS) quasi-Newton (*trainbfg*), as well as Levenberg Marquardt (*trainlm*). The network structure using logsig and linear (*purelin*) activation function at the hidden and output layer, respectively, and using the *trainlm* as a training function resulted in the best performance. Correlation coefficient ( $r$ ) of training and validation process were 0.97 - 0.99 and 0.92 - 0.99, whereas the MAE values ranged from 0.01 to 0.23 and 0.03 to 0.59, respectively.

**Keywords:** Artificial neural network, *trainlm*, tomato, RGB

## PENDAHULUAN

Warna merupakan faktor utama yang mempengaruhi persepsi konsumen terhadap kualitas produk secara keseluruhan (Francis, 1995). Alasan tersebut menyebabkan saat ini penelitian tentang penilaian warna pada bahan pangan dan hasil pertanian semakin berkembang. Hal itu didukung juga dengan makin beragamnya produk bahan pangan serta makin banyaknya teknik dan instrumen yang tersedia untuk tujuan-tujuan tertentu. Beberapa penelitian telah dilakukan

dengan tujuan untuk mengamati perubahan warna buah selama pemasakan (Saranwong dkk., 2004) dan penyimpanan (Žnidarcic dan Pozrl, 2006), melakukan klasifikasi (Du dan Sun, 2005) (Xiaobo dkk., 2007), serta menentukan kualitas (Kang dan Sabarez, 2009) (Ordenez-Santos dkk., 2008).

Penentuan warna tomat menggunakan spektrofotometer menunjukkan bahwa pada selama proses pemasakan warna tomat menjadi lebih gelap, rasio warna merah terhadap hijau meningkat, nilai kroma cenderung meningkat, serta sudut Hue menurun (Radzevičius dkk., 2009). Peningkatan rasio a/b

yang sejalan dengan meningkatnya kelas kemasakan (Batu, 2004), serta terjadinya hambatan perubahan warna tomat pada perlakuan dengan air panas dan penyimpanan pada  $O_2$  rendah (Ali, dkk., 2004) diamati dengan menggunakan chromameter. HunterLab yang digunakan untuk mengukur warna tomat menunjukkan hubungan signifikan antara warna dengan kelas kemasakan dan *firmness* (Hobson dkk., 1983), selain itu juga digunakan untuk menentukan kematangan mangga (Jha dkk., 2007).

Kualitas tomat antara lain ditentukan oleh warna, tekstur, flavor, serta kandungan nutrisi termasuk di dalamnya vitamin C. Selama pemasakan terjadi perubahan warna yang disebabkan oleh degradasi klorofil dan pembentukan karoten (Grierson dan Kader, 1986) selain terjadi metabolisme yang lain antara lain peningkatan kadar gula, penurunan rasio asam malat dan asam sitrat, dan penurunan keasaman total pada jaringan buah tomat yang terjadi selama pemasakan. Warna dan *flavor* biasanya digunakan oleh konsumen sebagai indikator pemilihan tomat. *Flavor* merupakan fungsi dari rasa dan aroma; dengan rasa dipengaruhi oleh gula terutama fruktosa dan glukosa, serta asam terutama sitrat, malat, dan keasaman total, sedangkan aroma dipengaruhi oleh komposisi senyawa volatil (Malundo dkk., 1995) (Mikkelsen, 2005). Selain itu, gula dan asam merefleksikan rasa keseluruhan dari buah (Azodanlou dkk., 2003).

Metode untuk menentukan kualitas secara non-destruktif menggunakan near infrared (NIR) spektroskopi semakin berkembang. Spektroskopi pada spektrum 1100 – 2200 nm digunakan untuk menentukan warna kopi saat penyangraian (Esteban-Diez dkk., 2004). Prediksi warna dan pH pada anggur dilakukan dengan menggunakan spektroskopi pada spektrum 400 – 1100 nm (Cozzolino dkk., 2004). Analisis kandungan pigmen yang berpengaruh terhadap warna juga dilakukan dengan menggunakan spektroskopi, antara lain kandungan karoten pada tomat (Clement dkk., 2008) dan semangka (Lewinsohn dkk., 2005).

Metode pengukuran dengan *machine vision* atau analisis citra untuk aplikasi pertanian (Chen dkk., 2002) juga semakin berkembang dewasa ini terutama karena dapat digunakan untuk menganalisis warna dari permukaan bahan yang tidak homogen yang tidak efektif apabila diukur dengan *color* meter (Balaban, 2008). Kamera CCD digunakan untuk mengukur kualitas tomat berdasarkan RGB (Lana dkk., 2006) atau permukaan makanan berdasarkan format *Lab* (Yam dan Papadakis, 2004). Kombinasi citra dari kamera dan spektrum digunakan untuk memprediksi kandungan Brix dari apel (Steinmetz dkk., 1999).

Kualitas pangan mempunyai beberapa indikator yang kompleks serta obyektif sehingga pendekatan secara matematika sering menghasilkan hasil yang tidak linier, tergantung

pada waktu, serta kadang mengandung persamaan-persamaan diferensial yang kompleks pula (Gnanasekharan dan Floros, 1995). Dengan jaringan syaraf tiruan (JST) maka pemodelan linier ataupun non-linier dari data dapat dilakukan secara cepat. JST juga mempunyai peran yang penting dalam metode analisis citra terutama dalam klasifikasi non-parametrik, persamaan regresi non-linier, atau untuk ekstraksi fitur (Egmont-Petersen dkk., 2002).

Optimasi menggunakan JST pada pengukuran kualitas bahan pertanian telah banyak diteliti. Bahan pertanian merupakan bahan heterogen sehingga JST merupakan metode yang handal digunakan untuk menyelesaikan model dengan variabilitas parameter yang tinggi (Gnanasekharan dan Floros, 1995). Analisis citra ditambah optimasi dengan JST dilakukan untuk mengklasifikasikan biji jarak (Effendi dkk., 2010) dan apel (Kavdir dan Guyer, 2004), melakukan prediksi terhadap bakteri koliform (Yin dan Ding, 2009), atau terhadap *firmness* dari buah pir (Zhou dan Li, 2007). Data spektra dari spektroskopi sebagai input dalam model JST juga banyak dilakukan. Data spektra tanaman teh pada tiga varietas dan tiga kebun digunakan sebagai masukan dalam penyusunan model JST untuk melakukan klasifikasi tanaman teh dengan akurasi 77% (Li dan He, 2008). Selain itu data spektra padi yang diukur menggunakan VIS/NIR spektrometri juga dapat digunakan untuk membedakan padi berdasarkan umur simpannya dengan akurasi model JST 97.5% (Li dkk., 2008).

Prediksi kualitas bahan pertanian berdasarkan parameter warna pernah dilakukan oleh Zambre dkk. (2010) dengan menggunakan parameter *redness* dari *Lab* untuk menentukan umur simpan tomat. Hubungan warna dalam format *Lab* dengan *firmness* tomat juga dilakukan oleh Batu (2004) yang menunjukkan bahwa jika rasio antara a/b mencapai 0.6–0.95 maka tomat dapat dijual secara mudah. Schouten, dkk. (2007) mengembangkan model matematika berdasarkan warna dan *firmness* untuk menentukan kualitas saat panen. Selain itu, karoten sebagai pigmen utama penentu warna pada tomat digunakan sebagai parameter aroma (Lewinsohn dkk., 2005). Parameter warna Red Green Blue (RGB) juga digunakan untuk mengamati perubahan warna tomat selama penyimpanan (Lana dkk., 2006).

Penelitian tentang prediksi kandungan substrat tomat selama penyimpanan belum pernah dilakukan, padahal terdapat hubungan antara perubahan warna dengan perubahan kandungan Brix, karoten total, asam sitrat, dan vitamin C selama penyimpanan. Parameter warna RGB cukup sederhana tetapi menghasilkan kualitas warna yang bagus dan kompatibilitasnya tinggi (Rehák dkk., 1999). Tujuan penelitian ini adalah untuk memprediksi kandungan Brix, karoten total, asam sitrat, dan vitamin C berdasarkan nilai RGB yang diperoleh dari CVS yang dikembangkan

pada penelitian sebelumnya (Masithoh, dkk., 2011) dengan menggunakan beberapa fungsi pelatihan JST yang akan diuji untuk memperoleh kinerja jaringan yang paling baik dalam melakukan prediksi tersebut.

## METODE PENELITIAN

### Sampel

Varitas tomat yang digunakan adalah varitas Marta dari Kaliurang berumur kurang lebih 2,5 bulan. Setelah dipetik dan dibersihkan, tomat dibiarkan pada suhu ruangan 27°C selama satu hari untuk dianalisis pada hari berikutnya meliputi warna (dalam format RGB), Brix, asam sitrat, vitamin C, dan karoten total.

### Warna RGB dan Parameter Kualitas Tomat

Tahap pertama penelitian ini adalah melakukan ekstraksi citra tomat untuk memperoleh informasi nilai RGB, kemudian melakukan analisis terhadap kandungan Brix, karoten total, vitamin C, dan asam sitrat dari tomat tersebut. Untuk memperoleh citra tomat dan menentukan nilai RGB-nya digunakan computer vision system (CVS) yang merupakan hasil dari penelitian terdahulu, dimana sudah dimasukkan operasi normalisasi untuk data warna dan parameter kualitas (Masithoh dkk., 2011). Citra tomat diambil sebanyak 3 (tiga) kali pada bagian permukaan yang berbeda kemudian citra disimpan dalam ukuran piksel 320x240. Setelah diambil citranya, tomat diukur parameter kualitasnya meliputi Brix, asam sitrat, vitamin C, dan karoten total berdasarkan metode dari AOAC International (2002), yang dinyatakan dalam %, mg/100g, dan mg/g, secara berturut-turut.

### Analisis Statistik Warna RGB dan Parameter Kualitas Tomat

Sebelum data RGB digunakan sebagai input pada JST, maka dilakukan uji statistik korelasi Pearson untuk melihat korelasi antara RGB sebagai input terhadap output yaitu parameter kualitas yang meliputi Brix, karoten total, asam sitrat, dan vitamin C. Parameter RGB yang korelasinya signifikan terhadap parameter kualitas tomat maka digunakan sebagai input dalam model JST.

### Pengembangan Model JST

Data yang digunakan secara total berjumlah 201 data yang dibagi menjadi 2 kelompok yaitu 1 kelompok yang terdiri dari 110 data sebagai data pelatihan dan kelompok lain terdiri dari 91 data sebagai data validasi. Data tersebut berasal dari sampel varitas yang sama. Tiap kelompok terdiri dari 2 bagian, yaitu sebagai masukan (nilai R, G, dan B) serta

keluaran (Brix, karoten total, asam sitrat, dan vitamin C). Algoritma JST yang digunakan untuk membentuk struktur model JST adalah *feedforward backpropagation* (perambatan galat balik); *backpropagation* dipilih karena algoritma tersebut mempunyai kecepatan proses dan struktur yang sederhana terutama untuk menyelesaikan hubungan nonlinier yang kompleks pada industri pertanian (Gnanasekharan dan Floros, 1995).

Data pelatihan digunakan untuk mendapatkan nilai bobot dan bias dari JST dengan fungsi aktivasi logsig pada lapisan tersembunyi dan linier (purelin) pada lapisan keluaran. Jumlah neuron pada lapisan masukan, jumlah lapisan tersembunyi dan jumlah neuron pada lapisan tersebut, serta jumlah neuron pada lapisan keluaran ditentukan. Matlab versi 7.01 (The MathWorks, Inc.) digunakan untuk menguji kehandalan model JST dengan jumlah neuron yang telah ditentukan tersebut. Pada proses pelatihan, *mean squared error* (MSE) digunakan sebagai parameter dari efektivitas pelatihan jaringan. Algoritma pelatihan meminimalkan MSE antara prediksi dan aktual sampai tercapai error yang minimal dengan maksimal iterasi 1000 epoch. *Learning rate* merupakan laju perubahan bobot selama pelatihan dan yang dipilih adalah *learning rate* yang rendah.

JST model yang dikembangkan menggunakan berbagai algoritma pelatihan, yaitu gradient descent (traingd), gradient descent dengan resilient backpropagation (trainrp), Broyden, Fletcher, Goldfrab dan Shanno (BFGS) quasi-Newton (trainbfg), serta Levenberg Marquardt (trainlm). Jaringan yang dipilih adalah yang mempunyai nilai koefisien korelasi (r) antara nilai aktual dan prediksi yang terbesar pada berbagai parameter kualitas tomat. Selain itu juga digunakan parameter *mean absolute error* (MAE) minimum pada iterasi yang terkecil digunakan sebagai parameter untuk memilih model JST yang terbaik.

Perhitungan MAE disajikan seperti Persamaan 1.

$$MAE = \frac{1}{n} \sum_{i=1}^n |C_A - C_P| \quad (1)$$

dengan  $C_A$  dan  $C_P$  merupakan kandungan Brix, karoten total, asam sitrat, atau vitamin C aktual dan prediksi, serta  $n$  adalah jumlah data.

### Kinerja Model JST yang Dikembangkan

Struktur model JST yang terpilih selanjutnya digunakan untuk melakukan validasi data. Pada struktur jaringan untuk validasi juga digunakan fungsi aktivasi logsig pada lapisan tersembunyi dan linier (purelin) pada lapisan keluaran. Sama seperti pada pelatihan, maka pada validasi ini ditentukan pula nilai koefisien korelasi (r) serta nilai MAE. Selanjutnya dilakukan analisis statistik menggunakan uji

t untuk menentukan apakah nilai *mean* (rata-rata) dari data aktual dan prediksi berbeda signifikan atau tidak pada tingkat kepercayaan 95%, untuk tahap pelatihan dan validasi. Pada akhirnya dilakukan plot regresi hubungan antara nilai Brix, karoten total, asam sitrat, dan vitamin C aktual dan prediksi pada data pelatihan dan validasi menggunakan JST dengan algoritma pelatihan yang terpilih. Model JST dinyatakan sebagai akurat jika mempunyai koefisien korelasi data aktual dan prediksi yang tinggi.

**HASIL DAN PEMBAHASAN**

**Pengembangan Model JST**

Tabel 1 menunjukkan hubungan statistik nilai warna R, G, dan B dengan parameter kualitas tomat yang diperoleh dari uji korelasi. Dari tabel tampak bahwa nilai warna R dan B tidak signifikan terhadap kandungan Brix, berbeda dengan nilai G. Sedangkan untuk kualitas lain yaitu karoten total, asam sitrat, dan vitamin C mempunyai hubungan yang signifikan dengan nilai R, G, dan B. Dengan menggunakan metode JST maka klasifikasi pola tetap dapat dilakukan meski hubungan antara data tidak signifikan (Effendi dkk., 2010).

Tabel 1. Korelasi warna RGB dengan parameter kualitas


Parameter kualitas	R	G	B
Brix	NS	*	NS
Karoten total	*	**	**
Asam sitrat	**	**	**
Vitamin C	**	**	**

\* : signifikan pada  $P < 0.05$   
 \*\* : signifikan pada  $P < 0.01$   
 NS : tidak signifikan

Data pelatihan digunakan untuk mendapatkan bobot dan bias dari struktur model JST dengan fungsi aktivasi logsig pada lapisan tersembunyi dan linier (purelin) pada lapisan keluaran. Tiga neuron digunakan dalam lapisan input, sebuah lapisan tersembunyi dengan 20 neuron, dan satu neuron pada lapisan output; terdapat empat struktur JST seperti tersebut untuk masing-masing output yaitu Brix, karoten total, asam sitrat, dan vitamin C. Gambar 1 menunjukkan struktur JST yang digunakan pada penelitian.

Pada proses pelatihan, *mean squared error* (MSE) digunakan sebagai parameter dari efektivitas pelatihan jaringan. Algoritma pelatihan meminimalkan MSE antara output target dan aktual sampai tercapai error yang minimal dengan maksimal iterasi 1000 epoch. *Learning rate* merupakan laju perubahan bobot selama pelatihan dan pada penelitian ini ditetapkan sebesar 0.01. Pemilihan nilai *learning rate* yang rendah dilakukan karena tingginya fluktuasi error selama

proses pelatihan jika nilai *learning rate* yang digunakan tinggi (Zhou dan Li, 2007).



Gambar 1. Struktur JST *feedforward backpropagation* yang digunakan pada penelitian. Masing-masing lingkaran mewakili satu neuron dan garis penghubung mewakili koneksi sinapsis. Jumlah neuron pada lapisan tersembunyi adalah 20. Satu neuron keluaran mewakili Brix, karoten total, asam sitrat, dan vitamin C.

Pada Tabel 2 tampak nilai koefisien korelasi (r) antara nilai aktual dan prediksi serta MAE pada pelatihan JST untuk berbagai parameter kualitas tomat. Dari tabel tersebut tampak bahwa nilai r tertinggi serta MAE terendah untuk semua parameter output tercapai pada jaringan dengan algoritma pelatihan trainlm. Dengan demikian pelatihan dengan algoritma trainlm dipilih sebagai model JST terbaik dan akan digunakan untuk melakukan validasi pada 91 data yang lain.

Tabel 2. Nilai koefisien korelasi (r) antara nilai aktual dan prediksi serta MAE (*mean absolute error*) pada berbagai jenis pelatihan JST

Jenis pelatihan	Brix		Karoten total		Asam sitrat		Vitamin C	
	r	MAE	r	MAE	r	MAE	r	MAE
Trainrp	0.81	1.51	0.99	0.11	0.95	0.71	0.97	0.31
Traingd	0.44	3.27	0.95	0.18	0.75	2.67	0.81	1.43
Trainlm	0.97	0.23	0.99	0.01	0.99	0.05	0.99	0.03
Trainbfg	0.96	0.27	0.99	0.01	0.97	0.29	0.98	0.19

Ket:  
 Trainrp : gradient descent dengan resilient backpropagation  
 Traingd : gradient descent  
 Trainlm : Levenberg Marquardt  
 Trainbfg : Broyden, Fletcher, Goldfrab dan Shanno (BFGS) quasi-Newton

**Kinerja Model JST yang Dikembangkan**

Pada struktur model JST yang terpilih yaitu struktur dengan algoritma pelatihan trainlm selanjutnya digunakan untuk melakukan validasi pada 91 data. Pada struktur jaringan untuk validasi juga digunakan fungsi aktivasi logsig pada lapisan tersembunyi dan linier (purelin) pada lapisan keluaran. Topologi jaringan yang digunakan untuk validasi

adalah 3, 15, 1 yang berarti 3 neuron pada lapisan masukan, 15 neuron pada satu lapisan tersembunyi, dan satu neuron pada lapisan keluaran.

Seperti tampak pada Tabel 3, nilai koefisien korelasi (r) pada tahap pelatihan dan validasi secara berturut-turut adalah 0.97 - 0.99 dan 0.92 - 0.99; sedangkan nilai MAE berkisar antara 0.01-0.23 dan 0.03-0.59. Dari hasil tersebut tampak bahwa struktur model JST yang dibangun dikatakan cukup akurat untuk memprediksi kandungan substrat pada tomat karena koefisien korelasi data aktual dan prediksi baik pada tahap pelatihan dan validasi mempunyai nilai di atas 0.9 (Williams, 2001).

Tabel 3. Nilai koefisien korelasi (r) dan MAE untuk tahap pelatihan dan validasi dengan menggunakan pelatihan trainlm

Parameter kualitas	Pelatihan		Validasi	
	r	MAE	r	MAE
Brix (°)	0.97	0.23	0.92	0.59
Karoten total (mg/g)	0.99	0.01	0.99	0.03
Asam sitrat (%)	0.99	0.05	0.98	0.23
Vitamin C (mg/100g)	0.99	0.03	0.97	0.22

Tabel 4 dan 5 menunjukkan nilai statistik dari data aktual kandungan Brix, karoten total, asam sitrat, dan vitamin C serta data prediksi-nya pada tahap pelatihan dan validasi

dengan jenis pelatihan trainlm. Secara sekilas dari kedua tabel tampak bahwa nilai dan distribusi data aktual dan prediksi menunjukkan data yang serupa, baik untuk data pelatihan atau validasi. Meskipun demikian, uji statistik tetap akan dilakukan untuk melihat apakah kandungan Brix, karoten total, asam sitrat, dan vitamin C berbeda secara signifikan antara data aktual dan prediksi, baik untuk data pelatihan maupun data validasi.

Analisis statistik menggunakan uji t digunakan untuk menentukan apakah nilai *mean* (rata-rata) dari data aktual dan prediksi berbeda signifikan atau tidak pada tingkat kepercayaan 95%, untuk tahap pelatihan dan validasi. Hasil menunjukkan bahwa diperoleh hasil bahwa untuk data pelatihan, nilai p yang diperoleh adalah 0.00, 0.938, 0.734, dan 0.837 untuk Brix, karoten total, asam sitrat, dan vitamin C, secara berturut-turut. Hal ini menunjukkan bahwa untuk tahapan atau data pelatihan, maka tidak terdapat beda signifikan antara data aktual dan prediksi menggunakan JST untuk semua parameter kualitas, kecuali Brix. Untuk tahap validasi ternyata mempunyai kecenderungan yang sama dengan tahap pelatihan, yaitu dengan nilai p sebesar 0.00, 0.877, 0.203, dan 0.208 untuk Brix, karoten total, asam sitrat, dan vitamin C. Maka dapat dikatakan bahwa untuk Brix terdapat beda signifikan antara data aktual dan prediksi, sedangkan untuk parameter lainnya tidak terdapat beda yang signifikan.

Tabel 4. Nilai statistik dari data aktual dan prediksi pada tahap pelatihan dengan jenis pelatihan trainlm

Parameter statistik	Brix		Karoten		Asam sitrat		Vitamin C	
	Aktual	Prediksi	Aktual	Prediksi	Aktual	Prediksi	Aktual	Prediksi
Mean	3.99	3.75	1.69	1.67	5.94	5.88	3.98	3.94
SD	0.36	0.34	1.67	1.65	1.30	1.28	1.43	1.42
Median	4	3.76	1.21	1.20	5.76	5.70	3.93	3.89
Variansi	0.21	0.18	2.74	2.69	2.06	2.02	2.13	2.09

Ket:

SD = standar deviasi

Tabel 5. Nilai statistik dari data aktual dan prediksi pada tahap validasi dengan jenis pelatihan trainlm

Parameter statistik	Brix		Karoten		Asam sitrat		Vitamin C	
	Aktual	Prediksi	Aktual	Prediksi	Aktual	Prediksi	Aktual	Prediksi
Mean	3.98	3.39	1.80	1.76	5.88	5.65	3.73	3.51
SD	0.38	0.32	1.59	1.55	1.26	1.21	1.23	1.16
Median	4	3.4	1.5	1.47	5.76	5.52	3.57	3.35
Variansi	0.14	0.10	2.53	2.43	1.60	1.48	1.52	1.34

## KESIMPULAN

Pada penelitian ini menggunakan trainlm pada algoritma JST, serta struktur jaringan menggunakan fungsi aktivasi logsig pada lapisan tersembunyi dan fungsi linier (purelin) pada lapisan keluaran. Topologi jaringan yang digunakan untuk pelatihan dan validasi secara berturut-turut adalah 3, 20, 1 serta 3, 15, 1 yang berarti 3 neuron pada lapisan input, 20 atau 15 neuron pada lapisan tersembunyi, dan satu neuron pada lapisan output. Learning rate yang digunakan adalah 0.01 dengan maksimum iterasi 1000 epoch. Nilai koefisien korelasi (r) pada tahap pelatihan dan validasi secara berturut-turut adalah 0.97 - 0.99 dan 0.92 - 0.99; sedangkan nilai MAE berkisar antara 0.01-0.23 dan 0.03-0.59. Hasil ini dapat dikatakan cukup akurat sehingga dapat disimpulkan bahwa model JST yang dikembangkan dapat digunakan untuk memprediksi kandungan Brix, karoten total, asam sitrat, dan vitamin C menggunakan parameter warna RGB.

## DAFTAR PUSTAKA

- Ali, M., Nakano, K. dan Maezawa, S. (2004). Combined effect of heat treatment and modified atmosphere packaging on the color development of cherry tomato. *Postharvest Biology and Technology* **34**: 113–116.
- AOAC International (2002). *AOAC official method 999.03*. Retrieved December 7, 2009, from <http://down.food126.com/standard/edit/UploadFile/2006423164428284.pdf>
- Azodanlou, R., Darbellay, C., Luisier, J. L., Villettaz, J. C. dan Amado, R. (2003). Development of a model for quality assessment of tomatoes and apricots. *Lebensm.-Wiss. U.-Technol* **36**: 223–233.
- Balaban, M. (2008). Quantifying nonhomogeneous colors in agricultural materials. Part I: Method development. *Journal of Food Science* **73**: 431-437.
- Batu, A. (2004). Determination of acceptable firmness and colour values of tomatoes. *Journal of Food Engineering* **61**: 471–475.
- Chen, Y., Chao, K. dan Kim, M. (2002). Machine vision technology for agricultural applications. *Computers and Electronics in Agriculture* **36**: 173-191.
- Clement, A., Dorais, M. dan Vernon, M. (2008). Nondestructive measurement of fresh tomato lycopene content and other physicochemical characteristics using Visible-NIR spectroscopy. *J.Agric. Food Chem.* **56**: 9813-9818.
- Cozzolino, D., Cynkar, W., Shah, N. dan Smith, P. (2011). Multivariate data analysis applied to spectroscopy: Potential application to juice and fruit quality. *Food Research International* **44**: 1888–1896.
- Du, C. J. dan Sun, D. W. (2005). Pizza sauce spread classification using colour vision and support vector machines. *Journal of Food Engineering* **66**: 137-145.
- Effendi, Z., Ramli, R. dan Ghani, J. A. (2010). A back propagation neural networks for grading *Jatropha curcas* fruits maturity. *American Journal of Applied Sciences* **7**: 390-394.
- Egmont-Petersen, M., de Ridder, D. dan Handels, H. (2002). Image processing with neural networks - a review. *Pattern recognition* **35**: 2279-2301.
- Esteban-Díez, I., González-Sáiz, J. dan Pizarro, C. (2004). Prediction of roasting colour and other quality parameters of roasted coffee samples by near infrared spectroscopy. A feasibility study. *J. Near Infrared Spectrosc.* **12**: 287-297.
- Francis, F. J. (1995). Quality as influenced by color. *Food Quality and Preferences* **6**: 149-155.
- Gnanasekharan, V. dan Floros, J. D. (1995). Back propagation neural networks: Theory and applications for food science and technology. In G. Charalambous, *Food Flavors: Generation, Analysis and Process Influence* (pp. 2151-2168). West Lafayette: Elsevier Science B.V.
- Grierson, D. dan Kader, A. A. (1986). Fruit ripening and quality. In J. G. Atherton, and J. Rudich, *The tomato crop: a scientific basis for improvement*. London: Chapman and Hall.
- Hobson, G. E., Adams, P. dan Dixon, T. J. (1983). Assessing the colour of tomato fruit during ripening. *J. Sci. Food Agric.* **34**: 286-292.
- Jha, S. N., Chopra, S. dan Kingsly, A. R. (2007). Modeling of color values for nondestructive evaluation of maturity of mango. *Journal of Food Engineering* **78**: 22–26.
- Kang, S. P. dan Sabarez, H. T. (2009). Simple colour image segmentation of bicolour food products for quality measurement. *Journal of Food Engineering* **94**: 21-25.
- Kavdir, I. dan Guyer, D. (2004). Comparison of artificial neural networks and statistical classifiers in apple sorting using textural features. *Biosystems Engineering* **89**: 331–344.
- Lana, M. M., Tijskens, L. M. dan Kooten, O. V. (2006). Modelling RGB colour aspects and translucency of fresh-cut tomatoes. *Postharvest Biology and Technology* **40**: 15-25.

- Lana, M. M., Tijskens, L. M., de Theije, A., Hogenkamp, M. dan van Kooten, O. (2006). Assessment of changes in optical properties of fresh-cut tomato using video image analysis. *Postharvest Biology and Technology* **41**: 296-306.
- Lewinsohn, E., Sitrit, Y., Bar, E., Azulai, Y., Ibdah, M., Meir, A., Emanuel Yosef, E., Zamir, D. dan Tadmoret, Y. (2005). Not just colors — carotenoid degradation as a link between pigmentation and aroma in tomato and watermelon fruit. *Trends in Food Science and Technology* **16**: 407-415.
- Li, X. dan He, Y. (2008). Discriminating varieties of tea plant based on Vis/NIR spectral characteristics and using artificial neural networks. *Biosystems Engineering* **99**: 313-321.
- Li, X., He, Y. dan Wu, C. (2008). Non-destructive discrimination of paddy seeds of different storage age based on Vis/NIR spectroscopy. *Journal of Stored Products Research* **44**: 264– 268.
- Malundo, T. M., Shewfelt, R. L. dan Scott, J. W. (1995). Flavor quality of fresh tomato (*Lycopersicon esculentum* Mill.) as affected by sugar and acid levels. *Postharvest Biology and Technology* **6**: 103-110.
- Masithoh, R., Rahardjo, B., Sutiarmo, L. dan Harjoko, A. (2011). Pengembangan computer vision system sederhana untuk menentukan kualitas tomat. *Agritech* **31**: 116-123.
- Ordóñez-Santos, L. E., Arbones, E., Vázquez-Oderiz, L., Romero-Rodríguez, A., Gómez, J. dan López, M. (2008). Use of physical and chemical properties of commercial tomato (*Lycopersicon esculentum* Mill.) products for monitoring their quality. *Journal of AOAC International* **91**: 112-122.
- Radzevičius, A., Karklelienė, R., Viškėlis, P., Bobinas, Č., Bobinaitė, R. dan Sakalauskienė, S. (2009). Tomato (*Lycopersicon esculentum* Mill.) fruit quality and physiological parameters at different ripening stages of Lithuanian cultivars. *Agronomy Research* **7** (Special issue II): 712–718.
- Rehák, R., Bodrogi, P. dan Schanda, J. (1999). On the use of the sRGB colour space. *Displays* **20**: 165–170.
- Saranwong, S., Sornsrivichai, J. dan Kawano, S. (2004). Prediction of ripe-stage eating quality of mango fruit from its harvest quality measured non-destructively by near infrared spectroscopy. *Postharvest Biology and Technology* **31**: 137-145.
- Schouten, R. E., Huijben, T. P., Tijskens, L. M. dan Van Kooten, O. (2007). Modelling quality attributes of truss tomatoes: linking colour and firmness maturity. *Postharvest Biology and Technology* **45**: 298–306.
- Steinmetz, V., Roger, J. M., Molto, E. dan Blasco, J. (1999). On-line fusion of colour camera and spectrophotometer for sugar content prediction of apples. *J. Agric. Engng Res.* **73**: 207-216.
- Williams, P. (2001). Implementation of near-infrared technology. In P. Williams, and K. Norris, *Near-infrared technology in the agricultural and food industries*. Minnesota: American Association of Cereal Chemists, Inc.
- Xiaobo, Z., Jiewen, Z. dan Yanxiao, L. (2007). Apple color grading based on organization feature parameters. *Pattern Recognition Letters* **28**: 2046–2053.
- Yam, K. L. dan Papadakis, S. E. (2004). A simple digital imaging method for measuring and analyzing color of food surface. *Journal of Food Engineering* **61**: 137-142.
- Yin, Y. dan Ding, Y. (2009). A close to real-time prediction method of total coliform bacteria in foods based on image identification technology and artificial neural network. *Food Research International* **42**: 191–199.
- Zambre, S., Venkatesh, K. dan Shah, N. (2010). Tomato redness for assessing ozone treatment to extend the shelf life. *Journal of Food Engineering* **96**: 463–468.
- Zhou, R. dan Li, Y. (2007). Texture analysis of MR image for predicting the firmness of Huanghua pears (*Pyrus pyrifolia* Nakai, cv. Huanghua) during storage using an artificial neural network. *Magnetic Resonance Imaging* **25**: 727–732.
- Žnidarcic, D. dan Pozrl, T. (2006). Comparative study of quality changes in tomato cv. ‘Malike’ (*Lycopersicon esculentum* Mill.) whilst stored at different temperatures. *Acta agriculturae Slovenica* **87**: 235 - 243.