

FAKTOR PENENTU SIFAT WARNA TANDAN BUAH SEGAR (TBS) SAWIT UNTUK MEMODELKAN KANDUNGAN MINYAK MENGGUNAKAN EVALUASI NONDESTRUKTIF FOTOGRAMMETRI

DETERMINANTS COLOR OF OIL PALM FRESH FRUIT BUNCH (FFB) TO PREDICT OIL CONTENT USING NONDESTRUCTIVE PHOTOGRAMMETRY

Dinah Cherie^{1)*}, Sam Herodian²⁾, Tineke Mandang²⁾, Usman Ahmad²⁾

¹⁾Departemen Teknik Pertanian, Fakultas Teknologi Pertanian, Universitas Andalas, Padang 25163, Sumatra Barat, Indonesia
E-mail: dinah.cherie@gmail.com

²⁾Departemen Teknik Pertanian dan Biosistem, Fakultas Teknologi Pertanian, Institut Pertanian Bogor, Indonesia

Makalah: Diterima 28 Agustus 2015; Diperbaiki 27 November 2015; Disetujui 14 Desember 2015

ABSTRACT

In this study, the oil palm fresh fruit bunch (FFB) was harvested and its images were recorded in a photographic studio. The bunch was recorded from various distances (2, 7, 10, 15m) using five lighting configuration, i.e. ultraviolet lamp (600 watts), visible lamp (600 and 1000 watt), as well as IR lamp (600 and 1000 watts). The FFB images were processed in order to obtain 15 colour components making up the image, consist of three primary colours (R, G, B) and their transformations (H, S, I, RI, GI, BI, RG, RB, GB, GR, BR, BG). The prediction model of FFB's oil content was built to evaluate the amount of oil on FFB accurately based on its image. The model was built using deep neural networks, where the colour components served as inputs, and 10 hidden layers were introduced to describe the relationship between all these variables and oil content. Of various recording setup, only four were selected based on their coefficient of correlation, namely: 10m_UV ($R^2 = 1$); 10m_Vis2 ($R^2 = 1$); 10m_IR2 ($R^2 = 1$); and 2m_IR2 ($R^2 = 0.981$). The determinant colour of the FFB's image which mostly influence the prediction models were the ratio of R to B (RB) for 10m_UV; the value of H and S on 10m_Vis2; the I and S of the 10m_IR2; and RB, H, and B for the 2m_IR2 treatment.

Keywords: deep neural network, FFB, nondestructive, oil content, photogrammetry

ABSTRAK

Pada penelitian ini tandan buah segar (TBS) sawit dipanen dan direkam gambarnya dalam sebuah ruang studio fotografi. TBS direkam dari berbagai jarak (2, 7, 10, 15 m) menggunakan lima konfigurasi pencahayaan, yaitu lampu ultraviolet (600 watt), lampu *visible* (600 dan 1000 watt), serta lampu *IR* (600 dan 1000 watt). Gambar TBS diolah sehingga diperoleh 15 komponen warna penyusun citra, yaitu tiga warna primer (*R, G, B*) serta hasil transformasi dari warna primer tersebut (*H, S, I, RI, GI, BI, RG, RB, GB, GR, BR, BG*). Sebuah model prediksi kandungan minyak TBS dibangun untuk mengevaluasi jumlah minyak pada TBS secara akurat. Model dibangun menggunakan *deepneural network* (jaringan saraf tiruan), dimana ke-15 komponen warna digunakan sebagai *input*, dan 10 *hidden layers* digunakan untuk menjelaskan keterkaitan antara seluruh variabel tersebut. Dari berbagai perlakuan perekaman citra TBS, model prediksi kematangan TBS pada empat perlakuan memberikan korelasi terbaik, masing masing adalah 10m_UV ($R^2=1$), 10m_Vis2 ($R^2=1$), 10m_IR2 ($R^2=1$), dan 2m_IR2 ($R^2=0,981$). Komponen warna dari citra TBS yang paling mempengaruhi model prediksi pada keempat perlakuan tersebut adalah rasio warna *R* terhadap *B* (*RB*) untuk perlakuan 10m_UV, nilai *H* dan *S* dari warna citra pada perlakuan 10m_Vis2, nilai *I* dan *S* dari warna citra pada perlakuan 10m_IR2, dan nilai *RB, H, dan B* dari citra TBS pada perlakuan 2m_IR2.

Kata kunci: fotogrammetri, JST, kandungan minyak, nondestruktif, TBS

PENDAHULUAN

Kelapa sawit merupakan salah satu komoditi unggulan Indonesia dan merupakan bagian dari komponen penggerak industri perkebunan. Setiap tahunnya Indonesia mampu menghasilkan lebih dari 31 juta ton hasil olahan kelapa sawit, berupa CPO (Agustine, 2015), yang sebagian besar diekspor ke manca negara, terutama India dan China (Cherie *et al.*, 2015a). Potensi ini sebenarnya dapat dimaksimalkan apabila produktivitas lahan sawit dapat ditingkatkan, salah satunya adalah dengan

mengoptimalkan hasil panen. Tandan buah segar (TBS) sawit, umumnya dipanen setelah umur pohon mencapai tiga tahun (Arisanti, 2015) atau lebih (Makky *et al.*, 2012), dan dilakukan secara terjadwal sesuai dengan alokasi panen di kebun. Namun demikian, berbagai faktor dapat mempengaruhi pertumbuhan TBS sehingga kematangan TBS pada satu pohon tidak sama dengan TBS yang berada pada pohon lainnya (Makky, 2005). Pemanenan terjadwal yang diterapkan tidak memperhatikan hal ini, sehingga sebagian TBS yang belum matang ikut dipanen karena sudah memasuki jadwal. Metode

pemanenan lainnya yang umum digunakan adalah metode panen terjadwal selektif. Pada metode ini, lokasi pemanenan di suatu kebun ditentukan sesuai jadwal, namun tidak semua TBS langsung dipanen pada lokasi tersebut, melainkan diseleksi sesuai dengan kematangannya. Acuan kematangan TBS yang digunakan pada sistem ini adalah dengan menghitung jumlah buah membrondol di sekitar pokok pohon sawit (Makky *et al.*, 2012a). Jumlah brondol yang umum digunakan adalah dua atau lebih, artinya, bila terdapat lebih dari dua buah brondol disekitar pokok sawit, maka TBS pada pohon tersebut dipanen. Pemanenan selektif ini juga memiliki kelemahan, terutama karena membrondolnya buah dari TBS dapat dipengaruhi oleh berbagai faktor, seperti angin dan hujan, gangguan hewan, dan hama penyakit (Makky *et al.*, 2012b). Akibatnya metode ini juga tidak memberikan hasil panen yang optimal. Oleh karena itu diperlukan suatu metode baru yang memungkinkan pemanenan TBS dilakukan saat kondisi buah tepat matang.

Pengembangan teknologi deteksi buah untuk menentukan kematangan guna mengambil keputusan panen telah tersedia dari berbagai hasil penelitian sebelumnya, seperti pada buah anggur (Pullido *et al.*, 2012), kesemek (Vahid *et al.*, 2015), pisang (Surya dan Satheesh, 2015), zaitun (Guzman *et al.*, 2015), pepaya (Amarasinghe dan Sonnadara, 2009), mangga (Rivera *et al.*, 2014; Ganiron, 2014; Nandi *et al.*, 2014), dan tomat (Yamamoto *et al.*, 2014). Namun demikian, untuk kelapa sawit, khususnya di Indonesia, hingga saat ini masih sangat terbatas (Makky dan Soni, 2013a, 2013b). Oleh sebab itu penelitian ini bertujuan untuk mengembangkan sistem deteksi kematangan TBS sawit yang dapat dipergunakan untuk membuat keputusan panen pada buah yang diamati.

Berbagai metode penentuan kematangan yang telah dikembangkan memiliki sifat merusak dan tidak merusak terhadap objek yang diamati (Makky, 2015). Kelebihan dari sistem pemeriksaan tidak merusak adalah objek yang diperiksa tidak terpengaruh oleh prosedur pemeriksaan (Irudayaraj dan Reh, 2007), sehingga nilai ekonomisnya tidak berkurang (Makky *et al.*, 2014). Berdasarkan hal ini, maka sistem deteksi kematangan untuk kelapa sawit yang dikembangkan pada penelitian ini adalah teknik pemeriksaan tidak merusak.

Salah satu tipe teknik pemeriksaan tidak merusak yang umum digunakan untuk produk pertanian adalah sistem *machine-vision* (Makky, 2005, 2013, 2015). Sistem ini bekerja dengan memanfaatkan teknologi perekaman visual untuk merekam gambar objek yang diteliti, lalu dilanjutkan dengan mengolah informasi pada citra yang dihasilkan. Informasi ini selanjutnya diolah menggunakan analisa statistik, untuk mengetahui hubungannya dengan parameter yang akan diukur. Sistem ini memiliki kelebihan dari segi kepraktisan

dan biaya yang cenderung lebih rendah dibandingkan tipe pemeriksaan lainnya (Makky *et al.*, 2012a, 2012b, 2014; Makky dan Soni, 2013a, 2013b, 2014). Mempertimbangkan hal ini, maka sistem deteksi kematangan TBS sawit dirancang menggunakan prinsip kerja dari *machine vision*.

Sistem kerja kamera umumnya adalah merekam berkas cahaya yang dipantulkan oleh suatu benda menggunakan sensor yang terdapat di dalam kamera. Spektrum cahaya terdiri dari berbagai jenis, namun secara umum dibagi dua berdasarkan penampakannya, yaitu cahaya tampak dan cahaya tidak tampak. Cahaya tampak adalah energi elektromagnetik yang memiliki panjang gelombang 400-700 nm, sedangkan cahaya tidak tampak adalah energi elektromagnetik yang memiliki panjang gelombang kurang dari 400 nm, atau lebih dari 700 nm. Ultraviolet (UV) adalah termasuk cahaya tidak tampak yang memiliki panjang gelombang 280-380 nm. Spektrum cahaya ini umum digunakan pada sistem pemeriksaan suatu produk pertanian yang bersifat tidak merusak (Cherie *et al.*, 2015a, 2015b). Cahaya UV yang umum digunakan adalah *UV-C* dengan panjang gelombang 320-380 nm. Selain *UV*, cahaya tidak tampak lainnya yang umum digunakan pada sistem pemeriksaan *machine-vision* adalah inframerah dekat (NIR). NIR memiliki spektrum mulai dari 720-4000 nm, dengan kemampuan sensor kamera untuk menangkap cahaya terbatas pada rentang UV C sampai dengan NIR A, yaitu antara 280-1100 nm. Namun demikian, pada kedua ujung batas rentang spektrum ini biasanya sensitivitas sensor kamera menyebabkan besarnya *noise* atau sinyal yang tidak diinginkan yang perbandingannya terhadap data *real* dari sinyal cahaya yang ditangkap memiliki rasio yang tinggi (Makky dan Soni, 2014). Oleh sebab itu, biasanya rentang spektrum yang digunakan pada sensor CMOS kamera memiliki batas mulai dari 320-1000nm.

Analisa citra dari suatu bahan pertanian dapat dilakukan dengan berbagai metode dan algoritma. Dalam kaitannya dengan penggunaan sistem pemeriksaan non destruktif untuk TBS sawit, maka beberapa penelitian sebelumnya menggunakan analisa diskriminan (Makky *et al.*, 2012b; Makky dan Soni, 2013b), regresi linear (Makky *et al.*, 2004; Makky, 2005), *principal component analysis* (PCA) (Makky dan Soni, 2014), regresi linear majemuk (Makky *et al.*, 2014; Makky, 2015), dan regresi kuadratik (Cherie *et al.*, 2015a). Berbagai metode yang digunakan dalam analisa citra ini memiliki kelebihan dan kekurangan masing-masing, namun pada dasarnya seluruh metode ini hanya dapat menjelaskan hubungan keterkaitan antara variabel yang *collinear*. Variabel yang memiliki variasi sangat besar dan hubungan antara variabel-variabel tersebut bersifat abstrak, diperlukan suatu analisis yang mendalam mengikuti hubungan model jaringan saraf (Makky dan Soni, 2014). Analisis ini dikenal dengan *neural network*

atau jaringan saraf tiruan (JST). Teknik JST sendiri memiliki berbagai variasi, seperti *back propagation*, *multilayer perceptron*, dan *deep neural network*. Di antara ketiga variasi ini, *deep neural network* memiliki kelebihan dari jumlah sampel yang dibutuhkan. Dengan jumlah sampel yang terbatas (kurang dari 30 sampel), *deep neural network* mampu menjelaskan hubungan antara variabel-variabel dari sampel tersebut secara akurat, dan membobotkan komponen dari tiap variabel dalam bentuk koefisien positif, maupun negatif, serta merangkai variabel-variabel tersebut dalam suatu model persamaan berlapis dalam beberapa *hidden layers*.

Berdasarkan hal tersebut di atas, penelitian ini bertujuan untuk menemukan metode terbaik untuk merekam TBS sehingga informasi yang terdapat pada citra hasil rekaman dapat dikorelasikan secara akurat dengan kematangan dan kandungan minyaknya menggunakan model algoritma *deep neural network*. Selain itu, sifat warna TBS yang dapat dijadikan sebagai faktor penentu untuk membangun model kandungan minyak juga dapat diidentifikasi pada penelitian ini.

BAHAN DAN METODE

Penelitian ini dilakukan pada bulan April 2013-Mei 2014. Pada penelitian ini, tanaman sawit yang menjadi objek adalah pohon sawit dengan umur 7-8 tahun berasal dari varietas "*Marihat*" yang terdapat pada perkebunan sawit di Pangkalan Bun, Kalimantan Tengah (2° 05' N, 111° 15' E). Tandan buah segar (TBS) yang direkam dipilih berdasarkan ciri-ciri kematangan yang umum, yaitu perubahan warna kulit buah dan jumlah berondol yang jatuh. Pengamatan kematangan dilakukan oleh tiga orang panel dari perkebunan, dan TBS dipilih bila seluruh panel sepakat bahwa objek tersebut telah matang dan siap panen. Selanjutnya TBS dipanen, dan dibersihkan, lalu dibawa ke dalam ruang studio fotografi untuk direkam. Metode perekaman gambar TBS dilakukan berdasarkan metode yang digunakan oleh Cherie *et al.* (2015a).

Kualitas sampel TBS yang digunakan pada penelitian ini diukur menggunakan analisa laboratorium, untuk menentukan kandungan minyak dan asam lemak bebas. Kedua parameter ini selanjutnya dijadikan acuan untuk mengembangkan model deteksi kandungan minyak TBS. Gambar TBS yang direkam dalam ruang foto studio diolah menggunakan program pengolahan citra untuk memperoleh nilai warna dalam bentuk data *R* (merah), *G* (hijau) dan *B* (biru). Ketiga nilai warna ini selanjutnya ditransformasikan menjadi 12 nilai lain berdasarkan metode yang dijabarkan dalam Cherie *et al.* (2015b). Seluruh nilai ini, selanjutnya distandarisasi dan dinormalisasi agar dapat dijadikan sebagai variabel masukkan (*input variable*) pada model penentuan kematangan TBS.

Sebuah program statistik (*SPSS 20.0*) digunakan untuk membangun model penentuan kematangan TBS menggunakan teknik *deep neural network*. Model dapat dibuat menjadi lebih akurat, maka kandungan minyak TBS dijadikan sebagai target model, dan sebanyak 10 *hidden layers* diintroduksikan dalam persamaan model. Data nilai warna TBS dari hasil perekaman dibagi dua yaitu sebagian (70%) digunakan untuk membangun model, sedangkan sisanya (30%) digunakan untuk menguji model. Untuk memvalidasi bahwa model yang dibangun memiliki akurasi yang baik, dan tidak bersifat *over-fit*, maka kesalahan prediksi diukur menggunakan koefisien korelasi (R^2) dan *root-mean-square-error* (RMSE). Dari semua konfigurasi perekaman gambar TBS yang dilakukan, dipilih model prediksi kematangan TBS yang mampu memberikan informasi kandungan minyak secara akurat pada setiap perlakuannya. Faktor penentu sifat warna TBS untuk memodelkan kandungan minyak menggunakan evaluasi nondestruktif fotogrammetri dipilih berdasarkan besaran kontribusi dari komponen warna tersebut terhadap pembentukan model, serta kalibrasi penyesuaian model.

HASIL DAN PEMBAHASAN

Dalam penelitian ini, terdapat 20 kombinasi perekaman citra TBS yang dilakukan dalam ruang studio fotografi, meliputi kombinasi pencahayaan, seperti spektrum cahaya, intensitas cahaya, dan jarak perekaman TBS. Tidak semua dari 20 kombinasi perekaman tersebut yang memberikan informasi yang dapat dimanfaatkan untuk memodelkan kandungan minyak TBS menggunakan JST. Beberapa kombinasi perekaman citra TBS memiliki korelasi yang sangat rendah antara komponen variabel dengan kandungan minyak, sehingga kombinasi ini dianggap kurang sesuai untuk digunakan sebagai metode evaluasi nondestruktif terhadap kandungan minyak TBS. Dari 20 kombinasi perlakuan perekaman citra TBS yang digunakan pada penelitian ini, hanya empat metode yang memiliki korelasi baik antara informasi warna pada citra dengan kandungan minyak sampel, yaitu metode 10 *m_UV*, 10 *m_Vis2*, 10 *m_IR2*, dan 2 *m_IR2*.

Perlakuan 10 *m_UV*

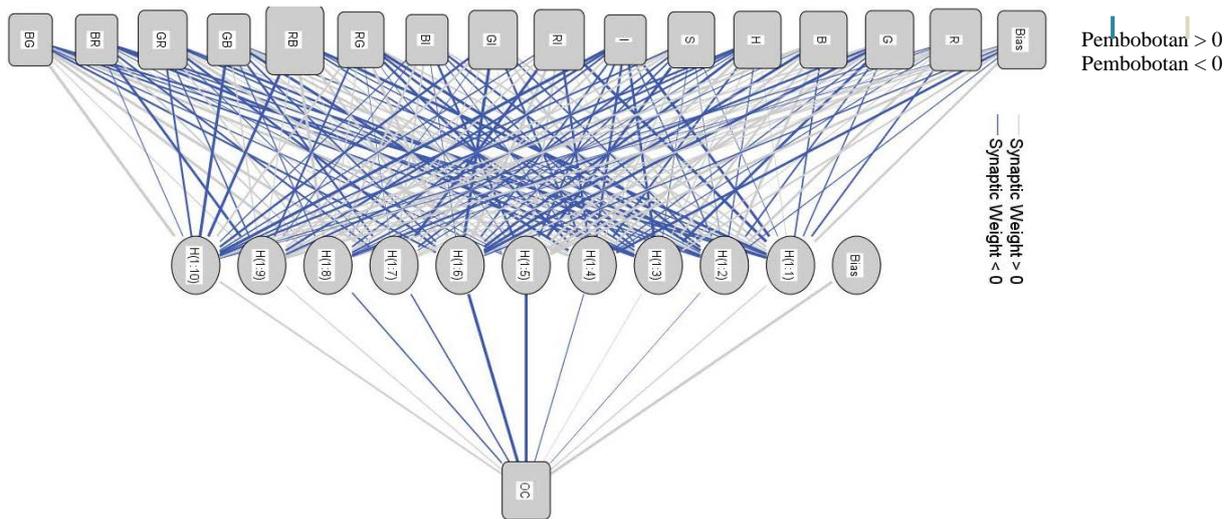
Perlakuan 10 *m_UV* adalah metode perekaman citra TBS pada ruang studio fotografi, dimana TBS direkam oleh kamera dari jarak 10 m menggunakan lampu pencahayaan ultraviolet (UV) dengan daya lampu terukur 600 watt. Citra TBS yang direkam pada perlakuan ini diolah menggunakan program pengolahan citra sehingga informasi komponen warna utama dapat diketahui, yaitu rata-rata dari nilai *R*, *G*, dan *B*. Komponen warna utama ini selanjutnya ditransformasikan

menjadi 12 komponen warna tambahan, sehingga secara keseluruhan ada 15 komponen warna yang dapat diekstrak dari setiap citra TBS yang direkam. Seluruh komponen warna TBS tersebut selanjutnya digunakan sebagai variabel *input* pada program pengolahan statistik dalam membangun model prediksi kandungan minyak TBS menggunakan JST. Model yang dihasilkan dari perlakuan ini dapat dilihat pada Gambar 1.

Pada Gambar 1 terlihat hubungan antara variabel masukan, *hidden layers*, dan target keluaran memiliki korelasi negatif maupun positif, ditandai dengan pembobotan *synaptic* yang dihasilkan oleh program pengolahan statistik saat membangun model. Korelasi positif ditunjukkan dari warna garis

hitam, sedangkan korelasi negatif ditunjukkan dengan warna garis abu-abu. Setiap garis menggambarkan besarnya keterhubungan antara dua komponen, dimana semakin besar keterkaitan kedua komponen tersebut, ketebalan garis semakin bertambah.

Hasil pengembangan model prediksi kandungan minyak TBS pada perlakuan ini tersusun dalam bentuk matrik dimana matrik pertama merupakan nilai koefisien dari setiap variabel masukan pada masing-masing *hidden layers*, sedangkan matrik kedua menunjukkan koefisien dari masing-masing *hidden layers* terhadap nilai kandungan minyak TBS. Matrik ini dapat dilihat pada Tabel 1.



Gambar 1. Diagram keterhubungan antara variabel *input*, *hidden layers*, dan target keluaran pada model prediksi kandungan minyak TBS yang dibangun berdasarkan informasi dari citra TBS yang direkam pada perlakuan 10m_UV menggunakan metode JST

Tabel 1. Nilai koefisien setiap komponen warna dari citra TBS pada masing masing *hidden layers* sebagai *input* untuk melatih JST yang dikembangkan menggunakan program statistik untuk membuat model prediksi kandungan minyak TBS pada perlakuan perekaman citra 10m_UV

Predictor		Predicted									
		Hidden Layer 1									
		H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)	H(1:6)	H(1:7)	H(1:8)	H(1:9)	H(1:10)
Input Layer	(Bias)	.436	-.113	.296	-.443	.447	-.195	.012	.235	.420	-.027
	R	-.258	.445	.108	-.117	.505	.223	.146	-.078	.058	-.121
	G	-.193	-.240	-.479	-.188	.528	-.530	.189	-.375	.039	.237
	B	-.227	.465	.412	.374	.428	-.513	.060	-.100	.432	.230
	H	.046	-.154	.145	-.335	.493	-.463	-.105	-.275	-.335	-.354
	S	-.043	-.025	-.054	.194	-.466	-.228	-.280	.364	.333	-.249
	I	-.483	-.153	-.464	-.438	-.287	-.256	.294	-.259	-.398	-.618
	RI	-.551	.370	.035	-.424	.331	.541	-.498	.253	.233	-.186
	GI	.345	-.240	.427	-.348	.019	-.638	.066	-.030	.410	-.400
	BI	.271	-.377	-.207	-.096	-.394	-.053	.262	.395	-.077	-.138
	RG	.254	-.568	-.421	-.457	-.043	.619	-.006	.132	-.309	.313
	RB	-.542	-.151	-.247	.153	.458	.446	.011	.573	.122	-.516
	GB	-.191	.372	.443	-.500	.200	-.251	-.368	-.125	.182	-.540
	GR	.224	-.417	-.226	.107	.606	-.425	-.103	.232	-.201	-.306
BR	-.390	-.217	-.460	.047	-.065	.050	-.304	.253	-.453	-.071	
BG	-.354	-.190	-.268	.465	-.170	-.324	.531	.479	.117	.606	
Output Layer(OC)	(Bias)	.160	-.015	.016	-.096	-.902	-.923	-.205	-.196	.127	.288
	0.516										

Dari Tabel 1 dapat dilihat bahwa model disusun menggunakan 10 *hidden layers*, dimana pada masing masing *layer* menghasilkan nilai koefisien untuk setiap komponen warna citra TBS bervariasi. Selain itu, pada baris terakhir tabel, terdapat besaran koefisien setiap *hidden layers* terhadap nilai prediksi kandungan minyak yang dihasilkan. Pada Tabel 1, terdapat besaran koefisien bernilai positif dan bernilai negatif. Sama seperti dengan diagram keterhubungan pada Gambar 1, maka besarnya nilai koefisien dan arah vektor dari setiap koefisien berbanding lurus dengan bobot *synaptic* model pada Gambar 1. Nilai *hidden layers* yang paling dominan adalah layer ke-5 dan ke-6.

Model prediksi kandungan minyak TBS yang dibangun pada perlakuan ini dapat secara akurat memperkirakan besarnya minyak yang terdapat pada TBS. Hal ini dapat dilihat dari nilai koefisien korelasi dari regresi hasil prediksi model dengan hasil pengukuran laboratorium, yaitu sebesar 1 (Gambar 2a). Nilai R^2 sebesar 1 menunjukkan bahwa nilai kesalahan prediksi dari model (RMSE) untuk menentukan kandungan minyak TBS dari sampel yang direkam sangat kecil (mendekati nol), sehingga tidak perlu diperhitungkan. Pada perlakuan ini, rasio warna merah terhadap biru (RB) (Gambar 2b) pada hasil rekaman citra TBS merupakan komponen warna paling penting dalam menentukan kandungan minyak TBS secara nondestruktif menggunakan teknik fotogrammetri.

Perlakuan 10 m_Vis2

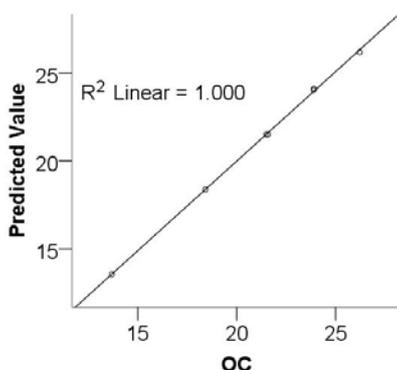
Perlakuan 10m_Vis2 adalah metode perekaman citra TBS pada ruang studio fotografi menggunakan kamera, dari jarak 10 m, dengan lampu halogen 1000 watt. Pada perlakuan ini, 15 komponen warna diekstrak dari setiap citra TBS yang direkam, dan digunakan sebagai variabel *input* pada program pengolahan statistik untuk membangun model prediksi kandungan minyak TBS

menggunakan JST. Besarnya keterhubungan model ini digambarkan dalam bentuk matrik koefisien dari setiap variabel masukan pada masing-masing *hidden layers*. Matrik ini dapat dilihat pada Tabel 2. Dari Tabel 2, dapat dilihat bahwa nilai koefisien untuk setiap komponen warna citra TBS bervariasi, pada masing-masing *layer*. Besaran koefisien tersebut bernilai positif dan negatif. Koefisien tersebut melambangkan besaran vektor yang berbanding lurus dengan bobot *synaptic* model. Berdasarkan nilai koefisiennya, *hidden layer* paling dominan adalah layer ke-9 dan ke-8.

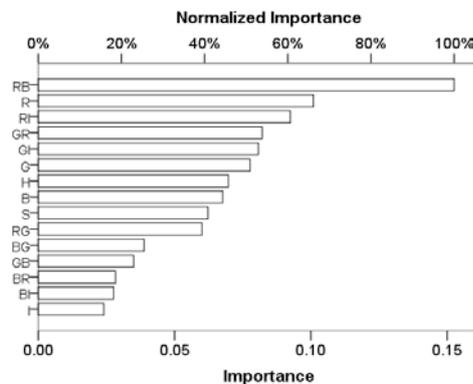
Model prediksi kandungan minyak TBS yang dibangun pada perlakuan ini juga dapat secara akurat memperkirakan kandungan minyak yang terdapat pada TBS. Nilai koefisien korelasi dari regresi linear antara hasil prediksi model dengan hasil pengukuran laboratorium menunjukkan R^2 sebesar 1 (Gambar 3a), menunjukkan bahwa nilai RMSE yang minimum, sehingga dapat diabaikan. Pada perlakuan ini, nilai Hue (H) dan Saturasi (S) (Gambar 3b) pada hasil rekaman citra TBS merupakan komponen warna dominan dalam penentuan kandungan minyak TBS secara nondestruktif menggunakan teknik fotogrammetri.

Perlakuan 10 m_IR2

Pada perlakuan 10 m_IR2, citra TBS direkam dalam ruang studio fotografi dari jarak 10 m menggunakan lampu halogen 1000 watt, serta sebuah filter IR pada lensa kamera. Citra TBS yang direkam pada perlakuan ini diolah untuk mendapatkan 15 komponen warna, yang digunakan sebagai variabel *input* pada program pengolahan statistik untuk membangun model prediksi kandungan minyak TBS menggunakan JST. Koefisien hubungan tiap komponen pada model prediksi kandungan minyak TBS pada perlakuan ini digambarkan dalam bentuk matriks seperti tersaji pada Tabel 3.



(a)



(b)

Gambar 2. Validasi akurasi model prediksi minyak menggunakan JST pada perlakuan 10 m_UV yang memiliki koefisien korelasi sebesar (R^2) = 1 (a), serta variabel masukan yang paling mempengaruhi nilai keluaran dari model, yaitu nilai rasio R terhadap B (RB) (b).

Tabel 2. Nilai koefisien setiap komponen warna dari citra TBS pada masing masing *hidden layers* sebagai *input* untuk melatih JST yang dikembangkan menggunakan program statistik untuk membuat model prediksi kandungan minyak TBS pada perlakuan perekaman citra 10 m_Vis2

Predictor	Predicted										
	Hidden Layer 1										
	H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)	H(1:6)	H(1:7)	H(1:8)	H(1:9)	H(1:10)	
<i>(Bias)</i>	-.500	-.355	.456	-.444	-.697	-.391	.456	.377	-.097	-.416	
<i>R</i>	-.195	.149	-.112	.439	.506	-.630	.600	.296	-.009	.237	
<i>G</i>	.005	.139	.254	.151	.108	-.348	.579	.153	-.637	.174	
<i>B</i>	.009	-.046	-.019	.443	.194	.453	-.449	.539	-.423	-.211	
<i>H</i>	-.020	-.019	-.247	-.301	.438	-.917	.011	-.778	-1.770	.114	
<i>S</i>	.644	.194	-.576	.290	-.030	-.402	.532	.518	-1.305	-.124	
<i>I</i>	-.043	-.706	-.082	.323	.277	-.274	.108	.171	1.149	-.568	
Input Layer	<i>RI</i>	-.212	-.281	-.638	-.459	.140	-.307	.047	-.759	-.682	-.261
	<i>GI</i>	.600	-.256	.551	.316	-.235	-.525	.518	-.226	.756	.454
	<i>BI</i>	-.340	-.052	.149	.563	-.391	-.595	-.553	-.921	-.028	-.044
	<i>RG</i>	.564	.454	.130	.253	-.174	-.148	-.289	-.342	-.880	.258
	<i>RB</i>	.247	.313	-.297	-.975	.204	-.079	.517	.449	-.388	-.164
	<i>GB</i>	-.136	.483	-.326	.348	-.129	.097	.108	.123	1.061	.015
	<i>GR</i>	-.138	-.162	.519	.760	-.634	.224	-.086	.284	.194	.434
	<i>BR</i>	.072	-.459	-.484	.249	.106	.039	.530	.190	-.207	.537
	<i>BG</i>	-.360	-.233	-.110	.178	-.311	-.375	-.343	-.478	-.825	-.467
Output Layer (OC)	<i>(Bias)</i>	-.338	-.350	.448	-.706	.320	.787	.260	.989	-1.651	-.098
	.125										

Dari Tabel 3 dapat dilihat bahwa *hidden layer* yang paling dominan adalah *layer* ke-4 dan ke-3. Korelasi setiap variabel masukan pada tiap *layer* menunjukkan kontribusi komponen warna terhadap pembentukan model. Nilai koefisien korelasi setiap komponen warna bervariasi, bernilai positif maupun negatif, sesuai dengan besar dan arah vektor pada diagram *synaptic* model.

Model prediksi kandungan minyak TBS yang dibangun pada perlakuan ini memiliki akurasi yang baik untuk menduga kandungan minyak pada TBS, terlihat dari nilai koefisien korelasi (R^2) model sebesar 1 (Gambar 4a). Nilai ini menunjukkan kesalahan prediksi model (RMSE) sangat kecil (mendekati nol), dan dapat diabaikan. Pada perlakuan ini, nilai *intensity* (I) dan saturasi (S) (Gambar 4b) pada hasil rekaman citra TBS merupakan komponen warna paling penting dalam menentukan kandungan minyak TBS secara non destruktif menggunakan teknik fotogrametri.

Perlakuan 2 m_IR2

Pada ketiga perlakuan sebelumnya, jarak perekaman TBS adalah 10 m, namun pada perlakuan ini, TBS direkam pada ruang studio fotografi dari jarak 2 meter. Lampu halogen 1000 watt digunakan untuk menerangi objek (TBS) dan sebuah filter IR digunakan pada lensa kamera. Sebanyak 15 komponen warna yang diekstrak dari citra TBS digunakan sebagai variabel *input* pada program pengolahan statistik untuk membangun model prediksi kandungan minyak TBS menggunakan JST. Besarnya hubungan antar komponen dalam model ini dijabarkan dalam bentuk matrik yang berisi nilai koefisien dari setiap variabel masukan pada masing-

masing *hidden layers*. Matrik ini dapat dilihat pada Tabel 4. Dari Tabel 4 dapat dilihat bahwa *hidden layers* yang paling berpengaruh pada model adalah *layer* ke-3 dan ke-9. Pada Tabel 4, besaran koefisien bernilai positif dan bernilai negatif.

Model prediksi kandungan minyak TBS yang dibangun pada perlakuan ini juga memiliki akurasi yang baik untuk memperkirakan kandungan minyak pada TBS. Nilai koefisien korelasi (R^2) model sebesar 0,981 (Gambar 5a) menunjukkan nilai kesalahan prediksi model (RMSE) masih dapat diterima, sehingga model dapat digunakan untuk memperkirakan kandungan minyak pada TBS. Pada perlakuan ini, nilai rasio R dan B, nilai H dan B (Gambar 5b) pada citra TBS merupakan komponen warna paling penting dalam menentukan kandungan minyak TBS secara non destruktif menggunakan teknik fotogrametri.

KESIMPULAN DAN SARAN

Kesimpulan

Pada penelitian ini telah berhasil dibangun model prediksi kandungan minyak TBS berdasarkan 15 informasi warna yang diperoleh dari hasil perekaman citra TBS pada empat konfigurasi perekaman, yaitu 10 m_UV, 10 m_Vis2, 10 m_IR2, dan 2 m_IR2. Akurasi dari keempat model prediksi kandungan minyak TBS diukur berdasarkan nilai koefisien korelasi (R^2) antara hasil prediksi dengan nilai kandungan minyak yang terukur, masing-masing sebesar 1; 1; 1 dan 0,981.

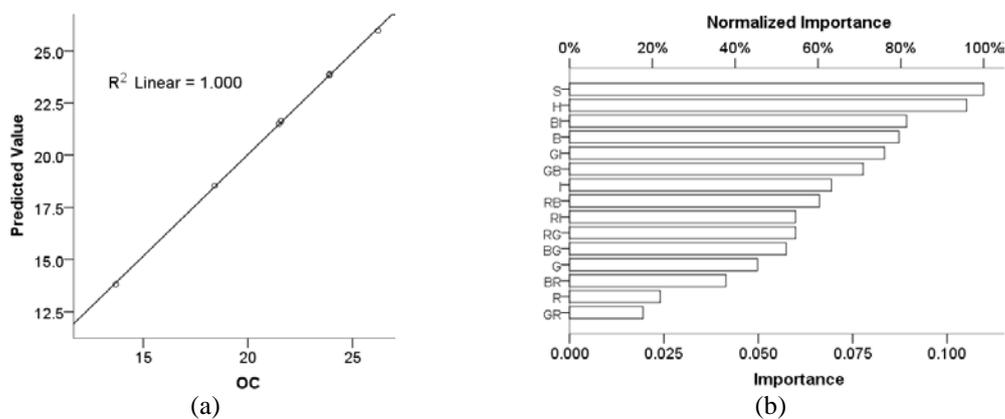
Komponen warna yang paling dominan dalam penentuan kandungan minyak TBS dari keempat perlakuan tersebut adalah rasio warna R

terhadap B (RB) untuk perlakuan 10 m_{UV}, nilai *H* dan *S* dari warna citra pada perlakuan 10 m_{Vis2}, nilai *I* dan *S* dari warna citra pada perlakuan 10 m_{IR2}, dan nilai RB, H, dan B dari citra TBS pada perlakuan 2m_{IR2}.

Saran

Penggunaan *deep neural network* (JST) pada penelitian ini memungkinkan dibangunnya

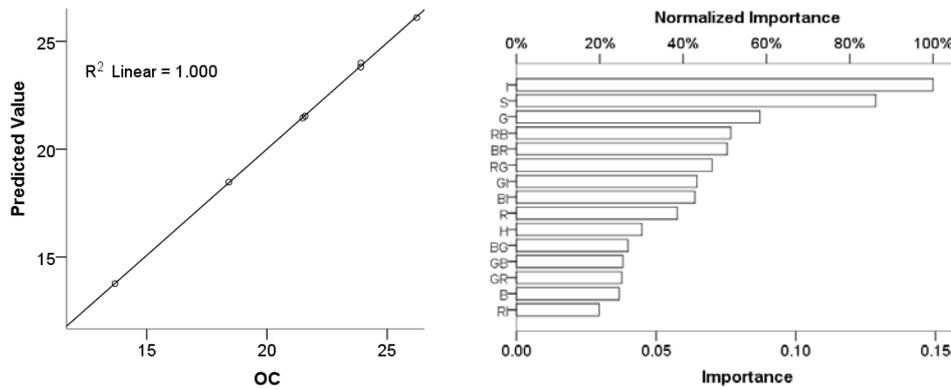
model prediksi kandungan minyak TBS dengan akurasi yang sangat baik, namun terbatas pada empat konfigurasi perekaman gambar. Penelitian ini dapat digunakan lebih luas, perlu ditelaah lebih lanjut berbagai konfigurasi perekaman TBS yang memungkinkan dibangunnya model prediksi kandungan minyak TBS dari berbagai jarak, pencahayaan dan spektrum.



Gambar 3. Validasi akurasi model prediksi minyak menggunakan JST pada perlakuan 10m_{Vis2} yang memiliki koefisien korelasi sebesar (R^2) = 1 (a), serta variabel masukan yang paling mempengaruhi nilai keluaran dari model, yaitu nilai *H* dan *S* (b).

Tabel 3. Nilai koefisien setiap komponen warna dari citra TBS pada masing masing *hidden layers* sebagai *input* untuk melatih JST yang dikembangkan menggunakan program statistik untuk membuat model prediksi kandungan minyak TBS pada perlakuan perekaman citra 10 m_{IR2}

Predictor	Predicted										
	Hidden Layer 1										
	H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)	H(1:6)	H(1:7)	H(1:8)	H(1:9)	H(1:10)	
(Bias)	.073	.710	-.301	-.004	-.346	.300	-.477	.727	.133	.092	
R	.223	-.118	.232	-.605	-.620	.099	-.030	-.009	-.162	-.386	
G	-.536	-.109	-.357	-.549	-.643	.296	.212	.356	.281	.392	
B	-.155	.449	-.179	-.492	.038	-.166	.245	.396	.103	-.443	
H	-.119	.066	.251	-.733	-.396	-.190	-.399	.159	-.340	-.196	
S	.558	-.064	-.342	-.336	-.084	-.219	.158	-.168	.456	.394	
I	.560	-.810	.128	-.707	-.468	.047	.389	.363	-.140	1.121	
RI	.009	-.677	.548	-.206	-.258	-.434	-.033	-.322	-.113	-.092	
GI	.174	.674	.477	.084	-.038	.372	-.289	-.035	-.070	-.491	
BI	-.088	-.314	-.555	-.009	.379	.081	-.210	-.532	.120	.586	
RG	.218	-.212	.478	.263	.083	.243	.234	.365	-.340	.122	
RB	.613	-.632	.304	-.573	-.287	.091	-.101	-.005	-.571	.304	
GB	-.595	.018	.086	-.237	-.272	-.212	-.310	.151	-.580	.035	
GR	.106	.770	-.257	.159	-.263	-.346	-.413	-.131	.355	.266	
BR	-.553	-.065	-.021	.699	-.404	.393	.045	-.158	.512	-.233	
BG	.324	-.324	-.573	.461	.192	-.383	-.444	-.563	.461	-.088	
Output Layer (OC)	(Bias) .895	-.809	.302	.904	1.567	.411	.210	-.112	.502	-.762	-.562



Gambar 4. Validasi akurasi model prediksi minyak menggunakan JST pada perlakuan 10 m_{IR2} yang memiliki koefisien korelasi sebesar (R^2) = 1 (a), serta variabel masukan yang paling mempengaruhi nilai keluaran dari model, yaitu nilai *I* dan *S* (b)

DAFTAR PUSTAKA

- Agustine I. 2015. Volume Ekspor *CPO* 2014 Naik. *Bisnis Indonesia*, bisnis.com 28 Januari 2015. <http://industri.bisnis.com/read/20150128/99/395909/volume-ekspor-cpo-2014-naik>. [22 Agustus 2015].
- Amarasinghe DI dan Sonnadara DUJ. 2009. Surface Colour Variation of Papaya Fruits with Maturity. *Proceeding of the Technical Session – International Conference: 25th Annual Technical Session of Institute of Physics Sri Lanka*. Institute of Physics, Sri Lanka. 19 Maret 2009. 25:21-28.
- Arisanti Y. 2015. Benih sawit unggul PT. ASD-Bakrie Oil Palm Seed Indonesia *DxP Spring* dan *DxP Themba*. Direktorat Tanaman Tahunan, Direktorat Jenderal Perkebunan, Kementerian Pertanian, <http://ditjenbun.pertanian.go.id/tanhun/berita-282-benih-sawit-unggul-pt-asdbakrie-oil-palm-seed-indonesia-dxp-spring-dan-dxp-themba.html>. [22 Mei 2015].
- Cherie D, Herodian S, Makky M, Mandang T, Ahmad U, Thoriq A. 2012. Application of Photogrametric Techniques to Determine the Maturity of Oil Palm Fresh Fruits Bunches. *Proceedings of ISAE National Seminar*. Universitas Brawijaya, Malang, Indonesia. 30 Nopember -2 Desember 2012. P166-177.
- Cherie D, Herodian S, Ahmad U, Mandang T, Makky M. 2015a. Optical characteristics of oil palm fresh fruits bunch (FFB) under three spectrum regions influence for harvest decision. *J Adv Sci Eng Inform Technol*. 5(3): e104-112.
- Cherie D, Herodian S, Ahmad U, Mandang T. 2015b. Camera-vision based oil content prediction for oil palm (*Elaeis Guineensis* Jacq) fresh fruits bunch at various recording distances. *J Adv Sci Eng Inform Technol*. 5(4): e317-325.
- Ganiron TU. 2014. Size properties of mangoes using image analysis. *J Bio Sci Bio Technol*. 6(2): e31-42.
- Guzman E, Baeten V, Pierna JAF, Mesa JAG. 2015. Determination of the olive maturity index of intact fruits using image analysis. *J Food Sci Technol*. 52 (3): e1462-70.
- Irudayaraj J dan Reh C. 2007. *Nondestructive Testing of Food Quality*. Wiley-Blackwell.
- Makky M. 2005. Pengembangan algoritma pengolahan citra pada sistem netra mesin 3D (3D Machine Vision) untuk robot pemanen kelapa sawit (*Elaeis guineensis* Jacq). [Tesis]. Bogor: Institut Pertanian Bogor.
- Makky M, Herodian S, Cherie D, Ahmad U, Mandang T. 2012a. Spectroscopy and Photogrammetric Techniques for Assessing Physicochemical Properties of Oil Palm (*Elaeis guineensis* Jacq) Fresh Fruits Bunch (FFB). *Proceedings of Research Dissemination Seminar -International Convention Center (IICC)*. Bogor, Indonesia. 10-11 Desember 2012.
- Makky M, Soni P, dan Salokhe VM. 2012b. Machine Vision Application in Indonesian Oil Palm Industry. *The Asian Forum of 2012 CSAM (Chinese Society for Agricultural Machinery) International Academic Annual Meeting. "Innovation, Win-win, Development"*. Hangzhou, China. 27-30 Oktober 2012.
- Makky M. 2013. Design and development of an automatic grading machine for oil palm (*Elaeis guineensis* Jacq) fresh fruits bunch (FFB) using nondestructive examination. [Disertasi]. Bangkok: Asian Institute Technology, Thailand.
- Makky M dan Soni P. 2013a. Towards sustainable green production: exploring automated grading for oil palm fresh fruit bunches (FFB) using machine vision and spectral

- analysis. *J Adv Sci Eng Inform Technol.* 3(1): 1-7.
- Makky M dan Soni P. 2013b. Development of an automatic grading machine for oil palm fresh fruit bunches (FFBs) based on machine vision. *J Comp Electron Agric.* 93: 129-139.
- Makky M dan Soni P. 2014. In situ quality assessment of intact oil palm fresh fruit bunches using rapid portable noncontact and nondestructive approach. *J Food Eng.* 120: 248-259.
- Makky M, Soni P, dan Salokhe VM. 2014. Automatic nondestructive quality inspection system for oil palm fruits. *J Agrophys.* 28: 319-329.
- Makky M. 2015. Trend in nondestructive quality inspections for oil palm FFB in Indonesia: a review. *J Agric and Agric Sci Procedia.* 20: 1-7.
- Nandi CS, Tudu B, dan Koley C. 2014. Machine vision based techniques for automatic mango fruit sorting and grading based on maturity level and size. Di dalam Mason A et al. (ed.), *Sensing Technol: Current status and futures trends II, smart sensors, measurements and instrumentation* 8. Switzerland: SpringerInt Pub.
- Pullido FJR, Robledo LG, Melgosa M, Gordillo B, Miret MLG, Heredia J. 2012. Ripeness estimation of grape berries and seeds by image analysis. *J Comp Electron in Agric.* 82: 128-133.
- Rivera NV, Sanchis JG, Perez JC, Carrasco JJ, Giraldo MM, Lorente D, Cubero S, Blasco J. 2014. Early detection of mechanical damage in mango using NIR hyperspectral images and machine learning. *J Biosystems Eng.* 122: 91-98.
- Surya PD dan Satheesh KJ. 2015. Assessment of banana fruit maturity by image processing technique. *J Food Sci Technol.* 52 (3): e1316-e1327.
- Vahid M, Kamran K, dan Varnamkhasti MG. 2015. Detecting maturity of persimmon fruit based on image processing technique. *J Sci Horti.* 184: 123-128.
- Yamamoto K, Guo W, Yoshioka Y, Ninomiya S. 2014. On plant detection of intact tomato fruits using image analysis and machine learning methods. *J Sensors.* 14(7): e12191-e12206.