

Aplicación de la tecnología de visión electrónica en la industria palmera de Indonesia*

Machine Vision Application in Indonesian Oil Palm Industry

AUTORES: Peeyush Soni y Muhammad Makky.

CITACIÓN: Soni, P., & Makky, M. (2016). Aplicación de la tecnología de visión electrónica en la industria palmera de Indonesia. *Palmas*, 37(Especial Tomo II), pp. 19-30.

PALABRAS CLAVE: ácidos grasos libres, contenido de aceite, madurez, no destructivo, RFF de palma de aceite, visión artificial.

KEYWORDS: Free fatty acids, oil content, maturity, not destructive, palm oil FFB, artificial vision.

*Artículo original recibido en inglés y traducido por Strong Tower Consulting.



PEEYUSH SONI

Profesor adjunto, Ingeniería y Sistemas Agrícolas, SERD, Instituto Tecnológico de Asia, Tailandia
Associate Professor, Agricultural Systems & Engineering, SERD, Asian Institute of Technology, Thailand
soni.ait@gmail.com

Resumen

En este estudio se utilizó la técnica no destructiva de la visión electrónica para evaluar la madurez de los racimos de fruta fresca (RFF) de palma de aceite, así como sus índices de calidad; se investigó el contenido de aceite (CA) y de ácidos grasos libres (AGL). En la práctica, los RFF se pueden clasificar en varias fracciones: F0, F1, F2, F3, F4 y F5. Dichas fracciones se correlacionan con el estado de madurez del racimo, desde un racimo verde (F0) a uno maduro (F2) y hasta uno excesivamente maduro (F5). La visión electrónica desarrollada en este estudio, compuesta por *hardware* y *software*, se utiliza para la adquisición y el procesamiento de imágenes con el fin de extraer sus características y determinar su fracción de madurez, el contenido de aceite y el nivel de ácidos grasos. Los resultados arrojaron que el sistema desarrollado tiene ventajas en su movilidad, en comparación con otros sistemas.

Abstract

In this study, a non-destructive technique namely machine vision for assessing the ripeness of oil palm fresh fruit bunches (FFB) as well as its quality indices; oil content (OC) and free fatty acid (FFA), was investigated. In practice, FFB can be distinguished into several fractions; F0, F1, F2, F3, F4, and F5. These fractions are correlated to the bunch ripeness state, from a raw bunch (F0) to the ripe (F2) and up to over ripe bunch (F5). The machine vision developed in this study comprised of hardware and software, for acquisition and processing of image to extract its features and determined the ripeness fraction together with oil content and free fatty acid level. Results showed that the developed system had the mobility advantages compared to other systems.

Introducción

En la economía indonesia la industria de la palma de aceite cumple una función importante debido a que es el principal producto de exportación y genera reservas de divisas. A pesar de los altos impuestos de países importadores y sanciones ocasionales de la Unión Europea y Estados Unidos por problemas relacionados con el medio ambiente y normas de la industria de la palma de aceite, este sector continúa siendo de importancia estratégica para el país. De acuerdo con la Dirección General de Cultivos (Ministerio de Agricultura), en el primer semestre de 2012 el área de cultivo de palma de aceite en Indonesia abarcaba 9,3 millones de hectáreas, mientras que el valor de las exportaciones en este mismo período fue de 9.952 millones de dólares y se calcula que la producción a finales de 2012 fue de 23,6 millones de toneladas (Ditjenbun, 2012).

En las normas se han prescrito claramente las disposiciones de calidad que, a su vez, se relacionan con la calidad del aceite producido. El aceite extraído del mesocarpio del fruto de la palma (*Elaeis guineensis* Jacq) se consideró comestible. La calidad del aceite de palma se ve muy afectada por la calidad de las materias primas, que son los racimos de fruta fresca (RFF) de palma de aceite. La calidad de los racimos se puede representar mediante tres factores: madurez, contenido de aceite (CA) y nivel de ácidos grasos libres (AGL). Generalmente, se observa que en la industria de la palma de aceite, donde los RFF se procesan en plantas de beneficio, no se obtiene la

calidad adecuada debido a la falta de continuidad en la supervisión manual o simplemente a descuidos en el proceso por limitaciones de mano de obra, tiempo y costos. Estos problemas podrían solucionarse mediante la introducción de sistemas rápidos y de bajo costo para la inspección de calidad de los RFF. Durante el proceso de inspección de calidad se prefieren los métodos no destructivos para reducir la pérdida de calidad de los RFF.

Las evaluaciones de calidad de los RFF, realizadas en años recientes, se han efectuado mediante diferentes métodos, como imágenes de cámaras fotográficas (Ismail *et al.*, 2000, Abdullah *et al.*, 2001, 2002, 2004, Idris *et al.*, 2003, Omar *et al.*, 2003, Rashid *et al.*, 2004, Alfatni *et al.*, 2008, Jaafar *et al.*, 2009, Jaffar *et al.*, 2009, Ismail y Hudzari, 2010, Tan *et al.*, 2010, Hazir y Shariff, 2011, Roseleena *et al.*, 2011), cálculo de tonalidad de color (Hudzari *et al.*, 2009, 2010, Ismail y Razali, 2010, Razali *et al.*, 2011), aplicación de espectroscopia de resonancia magnética nuclear (RMN) (Flingoh y Kamurind, 1989, Shaarani *et al.*, 2010), sistema de redes neuronales usando lógica Fuzzy (Nureize y Watada, 2008, Jamil *et al.*, 2009, Ghazalli, 2010), uso de imágenes hiperespectrales (Junkwon *et al.*, 2009), y la introducción de sensores electrónicos (Abbas, 1994, Yeow *et al.*, 2010, Saeed *et al.*, 2012).

Estas investigaciones arrojaron resultados aceptables en la etapa de laboratorio y dejan un campo de acción que se puede desarrollar posteriormente. Sin embargo, en la mayoría de estos trabajos se re-

quieren equipos sofisticados y, por ende, las técnicas y herramientas desarrolladas son de alta complejidad al momento de implementarlas en las plantas de beneficio. Esto, a su vez, dificultará el funcionamiento y reducirá la eficiencia de la aplicación de tales técnicas. Aunque algunas técnicas son fáciles de implementar, aún no pueden producir los resultados directamente, pues se deben realizar diversos análisis estadísticos y de laboratorio. Estas limitaciones ofrecen la oportunidad de tener un enfoque adecuado para elaborar evaluaciones no destructivas para determinar los parámetros de calidad de los RFF, con la facilidad de implementación, y con generación inmediata de los resultados de los análisis. El objetivo de este estudio fue utilizar técnicas móviles no destructivas basadas en la visión artificial para evaluar los parámetros de calidad de los RFF en operaciones de campo.

Materiales y métodos

Las muestras fueron racimos de fruta fresca (RFF) de palma de aceite (*Elaeis guineensis* Jacq) de palmas con una edad de 7 a 20 años. Todas las muestras se recolectaron en las plantaciones de la octava empresa nacional de cultivos, en las provincias de Java Occidental y Banten en Indonesia. Las palmas fueron de las variedades *tenera* y la madurez de los RFF se determinó de acuerdo con la norma (IOPRI, 1997) del Instituto Indonesio de Investigación de Palma de Aceite (Tabla 1). Debido a que es posible diferenciar las condiciones de madurez de los racimos por su color y la cantidad de frutos pequeños desprendidos, se solicitó que un panel de tres evaluadores expertos clasificaran los racimos en seis fracciones. Los racimos no tenían modificaciones de forma o peso antes de enviarlos al panel para su evaluación.

Tabla 1. Clasificación de fracciones de madurez de RFF (IOPRI, 1997).

Fracción de madurez	Estado de madurez	Frutos pequeños desprendidos	Color del racimo	Proporción permitida en el lote
F0	Racimo verde	0 % a 12,5 % de frutos externos	Negro violeta	< 3 %
F1	Racimo submadurado	12,5 % a 25 % de frutos externos	Violeta rojizo	> 85 %
F2	Racimo madurado	25 % a 50 % de frutos externos	Naranja rojizo	
F3		50 % a 75 % de frutos externos		
F4	Racimo sobremadurado	75 % a 100 % de frutos externos	Rojo oscuro	< 10 %
F5		Los frutos internos comienzan a desprenderse		< 2 %

Sistema de inspección de visión artificial

El sistema de inspección de visión artificial se compone de una cámara de inspección, un sistema de cámaras fotográficas y una computadora. La cámara de inspección puede analizar un RFF a la vez y sus dimensiones son 65 cm de ancho, 90 cm de largo y 65 cm de alto. La cámara es de madera contrachapada y el marco de madera liviana. Para iluminar la cámara se instalaron diodos emisores de luz (LED) a lo largo del perímetro superior interno de la cámara, de aproximadamente 500 lux de intensidad. La superficie interna de la cámara se lijó y pintó de blanco para que la luz se distribuyera de manera uniforme y

se redujera la dispersión en el proceso de generación de imágenes, pues los resultados podrían variar. Para alimentar la iluminación se utilizó una batería de polímero de litio (19 V, 6.600 mAh). En la parte superior de la cámara de inspección se instaló una cámara fotográfica (Finepix J27, Fuji Film, Japan) que apuntaba hacia abajo para capturar las imágenes del RFF dentro de la cámara. La cámara fotográfica se conectó a la computadora mediante una conexión USB. Luego, la imagen capturada se segmentó y se extrajeron los datos de atributos mediante un programa de procesamiento de imágenes. Los datos de atributos de la imagen fueron los datos RGB del objeto de RFF capturado. El programa de procesamiento de imágenes se

creó con una interfaz de programación de aplicaciones (API) nativa de Win32 y el *software* se desarrolló con herramientas de desarrollo C# (SharpDevelop 3.2, IC#Code Team). Los datos RGB se procesaron nuevamente para ajustarlos al procesamiento de imágenes del modelo de color HSI (matiz (H), saturación (S) e intensidad (I)) (González y Woods, 2008). Asimismo, los datos de RGB se normalizaron en r (rojo), g (verde) y b (azul), mediante las siguientes ecuaciones:

$$r = \frac{R}{R + G + B} \quad (1)$$

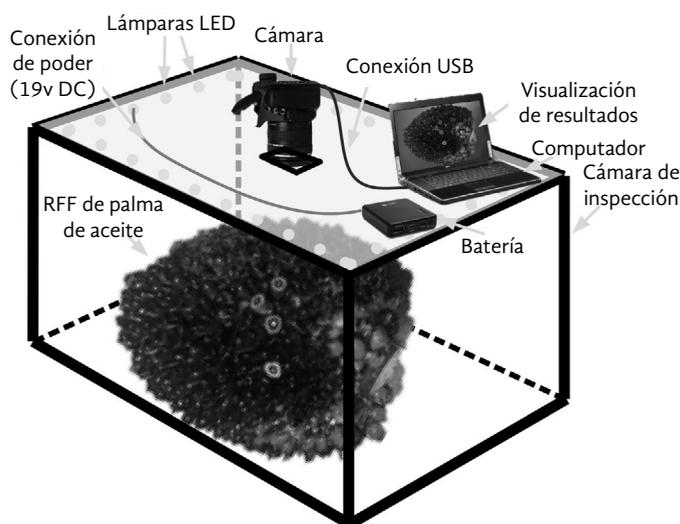
$$g = \frac{G}{R + G + B} \quad (2)$$

$$b = \frac{B}{R + G + B} \quad (3)$$

A partir de cada imagen, se comparó el promedio de los atributos de datos, que se componen de R, G, B, H, S, I, r, g y b, con los resultados de la fracción

correspondiente de madurez del RFF, así como con su contenido de aceite y nivel de ácidos grasos libres obtenidos en los análisis de laboratorio. A fin de clasificar la fracción de madurez del RFF este se clasificó en tres clases de madurez: sin madurar (Clase 1), maduro (Clase 2) y sobremaduro (Clase 3), con un análisis discriminado mediante una función discriminante canónica. Las muestras consisten en 180 RFF, 30 de cada fracción (F0 a F5). En cuanto al modelado del contenido de aceite y de ácidos grasos libres, se utilizó un *software* de ingeniería estadística para correlacionar los resultados de laboratorio con los atributos que se extrajeron de las imágenes mediante el método de regresión. Para eliminar las variables no significativas ($p > 0,1$) de los modelos, se efectuó la prueba F. Se utilizaron 90 RFF, 15 de cada fracción, para determinar el contenido de aceite y el nivel de ácidos grasos libres. Los datos de las muestras se dividieron en dos partes: dos tercios de los datos se utilizaron en la instrucción y calibración de los modelos y el otro tercio, en la validación. El sistema de visión artificial se presenta en la Figura 1.

Figura 1. Componentes del sistema de visión artificial.



Análisis de laboratorio

Después de hacer las mediciones con los dos sistemas, se llevaron a cabo análisis químicos en el laboratorio para medir el contenido de aceite y el nivel de ácidos grasos libres de cada racimo. Para desactivar las enzimas de lipasa de los frutos, las muestras se hirvieron

de inmediato; después, los frutos se desprendieron del racimo y se cortaron para separar el mesocarpio. El aceite del mesocarpio se extrajo mediante un procedimiento gravimétrico, de acuerdo con la norma nacional de Indonesia SNI-01.2981.1992 (NSAI, 2006). El contenido de aceite en el mesocarpio (Oil_m) se calculó así:

$$\% Oil_m = \frac{W_1 - W_2}{W_3} \times 100\% \quad (4)$$

Donde: W_1 es el peso del fruto y el aceite (g), W_2 es el peso del fruto vacío (g), y W_3 es el peso de la muestra de mesocarpio (g).

El contenido real de aceite de la muestra de RFF se calculó con la siguiente ecuación:

$$\% Oil Content (OC) = \frac{\sum M_f}{M_{FFB}} \% M_m \% Oil_m \quad (5)$$

Donde: M_{RFF} es el peso del RFF (kg), M_f es el peso de los frutos pequeños (kg), $\% M_m$ es el porcentaje del peso del mesocarpio de los frutos pequeños (%), y $\% Oil_m$ es el porcentaje de aceite de mesocarpio (%).

El nivel de ácidos grasos libres en el aceite extraído se midió mediante titulación. El porcentaje de AGL se calculó como el ácido palmítico de KOH (en miligramos) necesario para contrarrestar el ácido de 1 g de muestra. En esta investigación, los AGL se midieron siguiendo el procedimiento del método oficial Ca 5a-40 de la Sociedad Estadounidense de Químicos Aceiteros (AOCS, 2004).

El porcentaje de AGL (a manera de palmíticos) se expresó de la siguiente manera:

$$\% FFA (as palmitic) = \frac{25,6 N V}{W} \quad (3)$$

Donde: V es el volumen de KOH (ml); N es la solución de titulación normalizada, W es el peso de la muestra (g), y 25,6 es la constante (para calcular el AGL como ácido palmítico).

Resultados y discusión

El peso total del sistema de inspección de visión artificial que se desarrolló fue inferior a 7 kg, por lo que el sistema se puede movilizar. Solo se necesita un operario para manejar el sistema. Sin embargo, como este funciona con baterías, puede operar solo durante cuatro horas y necesita recargarse, por lo que se requieren dos horas más para terminar el proceso de recarga.

El sistema de inspección de visión artificial se sometió a varias pruebas y los resultados sirvieron para validar la exactitud del sistema y el principio de fun-

cionamiento del sistema de adquisición de imágenes, así como el programa de procesamiento de imágenes. El sistema funcionó según lo previsto durante las pruebas de condiciones del campo. En la cámara de inspección pudieron colocarse los RFF, que tenían varias dimensiones. La iluminación interior de la cámara de inspección proporcionó las condiciones deseadas para la adquisición de imágenes con la cámara fotográfica. Las imágenes capturadas se procesaron mediante el software de procesamiento de imágenes, que efectuó las operaciones de segmentación, extracción de atributos y toma de decisiones con base en la imagen. La segmentación de las imágenes se hizo mediante técnicas de umbralización adaptativa. Se extrajeron nueve atributos de la imagen objeto que consisten en los canales de color rojo (R), verde (G) y azul (B), así como en los datos de cromaticidad, que se componen de matiz (H), saturación (S) e intensidad (I). Los demás atributos fueron el valor de normalización de los canales de colores, que son r, g, y b, y se obtuvieron mediante las ecuaciones 1, 2 y 3, respectivamente. Luego, la media de estos datos se utilizó en los análisis de clasificación mediante un análisis discriminado en etapas. El resultado se presenta en la Tabla 2.

Tabla 2. Coeficientes de la función discriminante canónica.

	Función	
	1 (eje X)	2 (eje Y)
R	-0,025	0,024
G	0,138	0,067
B	-0,078	-0,095
r	-1,622	6,985
g	-6,659	19,462
b	17,382	-25,915
H	0,017	0,061
S	0,030	0,000
(Constante)	-7,843	-11,745

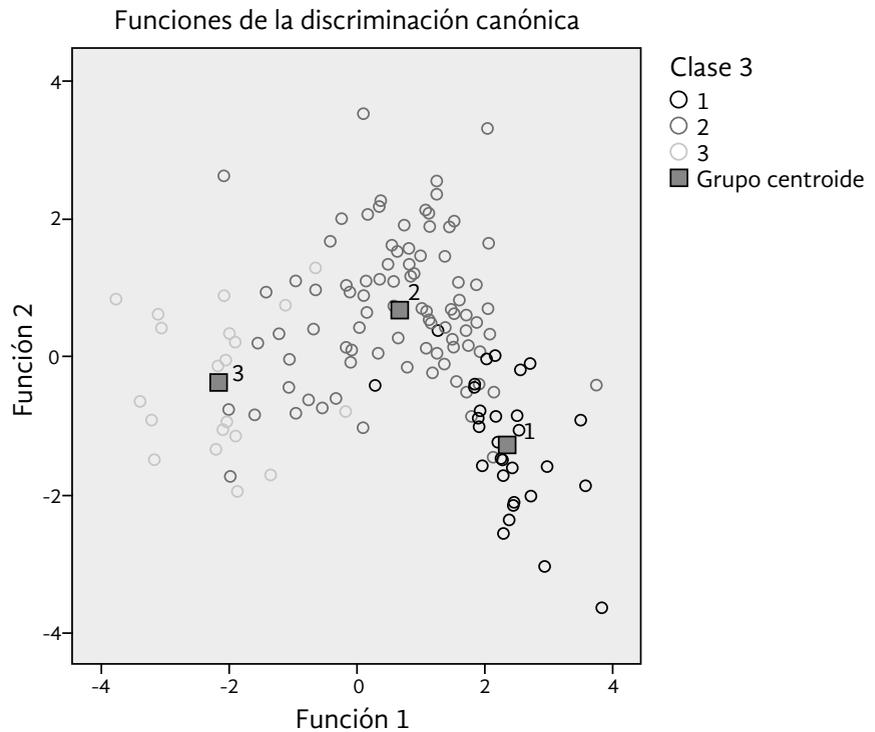
Coeficientes no estandarizados

El coeficiente de la función discriminante canónica describió los coeficientes de la ecuación para discriminar los RFF. Cada media de atributos de datos se multiplicó por el coeficiente correspondiente de la

Tabla 2. Los resultados de la suma tanto en la función 1 como en la función 2 fueron el producto de la multiplicación de cada media de atributos con el coeficiente correspondiente. El resultado de la función 1 sirve

como coordenada del eje X, mientras que el resultado de la función 2 sirve como coordenada del eje Y. Los resultados se trazaron en una gráfica, como se muestra en la Figura 2.

Figura 2. Resultados de la discriminación canónica.



En la Figura 2 se muestra que los resultados de la discriminación de todos los RFF se dispersaron y se pueden agrupar en tres clases, y el centro de cada una se describe en la Tabla 3.

Tabla 3. Funciones en los centroides de grupos.

Clase	Función	
	1 (eje X)	2 (eje Y)
1	2,341	-1,275
2	0,663	0,677
3	-2,166	-0,378

Funciones discriminantes canónicas no estandarizadas evaluadas en promedios de grupos

El punto central de la clase 1, en la coordenada (x, y), fue (2,341 -1,275), el punto central de la clase 2 fue

(0,663 y 0,667) y el punto central de la clase 3 fue (-2,166 y 0,378). El resultado de la discriminación canónica de cada RFF se comparó con estos tres puntos centrales mediante el análisis de distancia euclidiana cuadrada. Los RFF con un resultado más cercano al punto central de una clase pertenecerá a dicha clase, y el resultado de la clasificación de todos los RFF se determinó con este método, como se presenta en la Tabla 4.

El sistema de inspección de visión artificial clasificó correctamente 85 % de las muestras de RFF. Estos resultados se consideraron aceptables, según los criterios que se describen en la Tabla 1. Para evaluar el desempeño de la clasificación, se hizo un análisis de curva ROC (característica operativa del receptor), que sirvió para obtener una mejor comprensión de la sensibilidad y especificidad equilibrada del desempeño de la clasificación. El análisis de curva ROC se presenta en la Figura 3.

Tabla 4. Resultados de la clasificación^{a, b}

		Clase	Perteneencia al grupo previsto			Total
			1	2	3	
Original ^a	Recuento	1	24	6	0	30
		2	4	75	11	90
		3	0	6	54	60
	%	1	80,0	20,0	0,0	100,0
		2	4,4	83,3	12,2	100,0
		3	0,0	10,0	90,0	100,0
Con validación cruzada ^b	Recuento	1	24	6	0	30
		2	5	73	12	90
		3	0	9	51	60
	%	1	80,0	20,0	0,0	100,0
		2	5,6	81,1	13,3	100,0
		3	0,0	15,0	85,0	100,0

^a 85,0 % de los casos agrupados originales correctamente clasificados.

^b La validación cruzada solo se realiza para los casos del análisis. En la validación cruzada, cada caso se clasifica según las funciones derivadas de todos los demás casos.

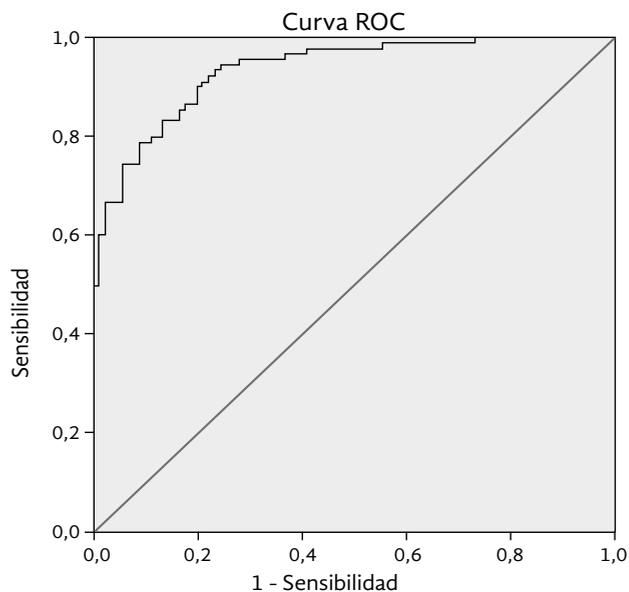


Figura 3. Desempeño de la clasificación de racimos de fruta fresca con el análisis de curva ROC.

La curva ROC describió la exactitud de la clasificación de RFF según el área debajo de la curva. El área cerca al 1 indica que el modelo separó las clases de manera

significativa, mientras que el área de 0,50 muestra que el predictor no es mejor que las probabilidades. Los resultados del análisis de curva ROC se describen en la Tabla 5.

Tabla 5. Área bajo la curva

Variable(s) de los resultados de la prueba: Probabilidades de pertenencia al grupo 2 para el análisis 1				
Área	Error estándar ^a	Significación asintótica ^b	Intervalo de confianza del 95% asintótico	
			Cota inferior	Cota superior
0,935	0,017	0,000	0,902	0,968

^a Bajo supuestos no paramétricos

^b Hipótesis nula: área real = 0.5

El área bajo la curva es 0,935, con un intervalo de confianza de 95 %. La cota inferior fue 0,902, mientras que la superior fue 0,968. Los resultados demostraron que la clasificación de RFF tuvo un desempeño satisfactorio y significativamente diferente del área real de la hipótesis nula.

En el modelo de contenido de aceite del RFF se hizo un análisis de regresión lineal múltiple. Los atributos extraídos de la imagen objeto se consideraron una entrada de datos del predictor luego de generar el modelo, mientras que las mediciones del contenido de aceite de RFF obtenidas en los análisis de laboratorio se consideraron el resultado objetivo. A partir de la calibración, los coeficientes de la regresión lineal múltiple canónica se presentan en la Tabla 6.

El coeficiente canónico describió los coeficientes de la ecuación para el modelo del contenido de aceite en RFF. Cada media de datos de atributos se multiplicó por cada coeficiente de la Tabla 6. Los resultados de la suma representaron el valor previsto de contenido de aceite en la muestra correspondiente. El desempeño del modelo, después de las calibraciones y validaciones, se presenta en la Figura 4.

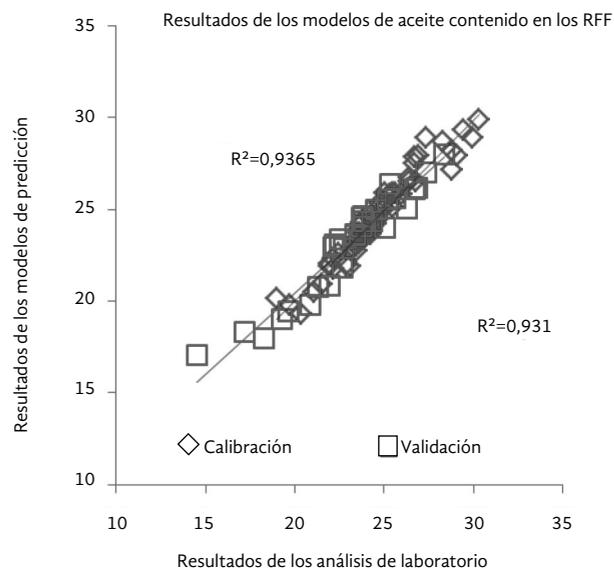
El modelo de contenido de aceite del sistema de inspección de visión artificial logró un desempeño aceptable después de la calibración ($R^2_{\text{calibración}}$) y validación ($R^2_{\text{validación}}$) (Figura 4). El coeficiente de determinación del modelo en calibración ($R^2_{\text{calibración}}$) fue

0,9365 con un error estándar de calibración (SEC) de 0,6164. En la calibración del modelo se utilizó la información de 60 muestras de RFF, mientras que en la validación del modelo, la información de 30 muestras de RFF, con $R^2_{\text{validación}}$ de 0,931 y error estándar de predicción (SEP) de 0,821. Se consideró que el modelo tuvo éxito, dado que los valores R^2 , tanto en calibración como en validación fueron altos, mientras que los valores de SEC y SEP fueron bajos. Las pequeñas diferencias entre el SEC y el SEP indicaron que el modelo calculó las variables latentes mínimas y los ruidos no se modelaron. Se esperaba una cantidad relativamente baja de variables latentes para evitar el modelado de señal/ruido.

Tabla 6. Coeficientes de la función de regresión lineal múltiple canónica del modelo de contenido de aceite.

Función	
(Constante)	5,176
R	0,050
G	0,076
B	-0,080
R	-4,976
G	55,553
B	-46,966
H	0,110
S	0,034
I	-0,064

Figura 4. Desempeño del modelo de contenido de aceite del sistema de inspección de visión artificial.



En el modelado de los ácidos grasos libres del RFF se aplicó un análisis de regresión estadística similar (RLM). Después de la calibración, el modelo produjo coeficientes de regresión lineal múltiple canónica de la predicción de ácidos grasos libres, como se presenta en la Tabla 7.

De manera similar al modelo de CA, en el modelo de AGL cada media de datos de atributos se multiplicó por el coeficiente correspondiente en esta Tabla. El valor de predicción de AGL se obtuvo al sumar las multiplicaciones. El desempeño del modelo de AGL después de las calibraciones y validaciones se presenta en la Figura 5.

Tabla 7. Coeficientes de la función de regresión lineal múltiple canónica del modelo de ácidos grasos libres.

	Función
(Constante)	-3,418
R	0,065
G	0,084
B	-0,049
r	14,397
g	8,516
b	-7,673
H	0,018
S	-0,032
I	-0,108

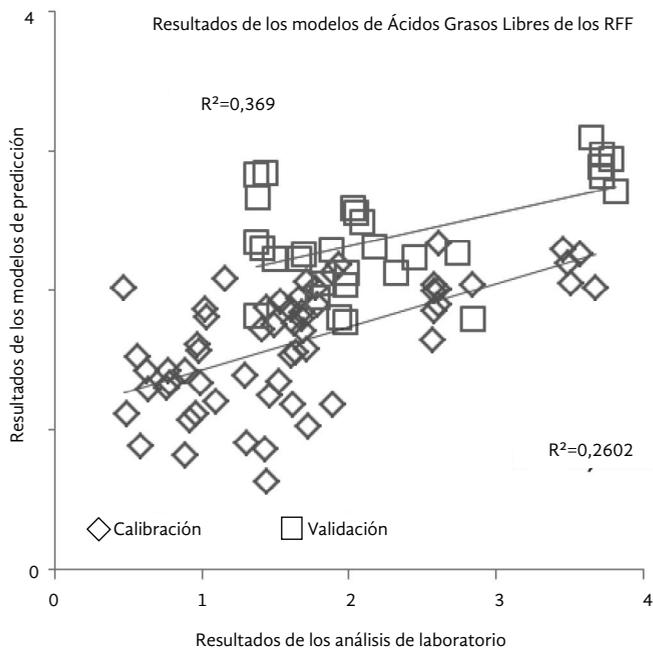


Figura 5. Desempeño del modelo de AGL del sistema de inspección de visión artificial.

El modelo de ácidos grasos libres del sistema de inspección de visión artificial logró un desempeño deficiente en calibración y validación (Figura 5). El resultado bajo en el coeficiente de determinación del modelo en cuanto a calibración ($R^2_{\text{calibración}} = 0,369$) o validación ($R^2_{\text{validación}} = 0,26$) sugirió que el modelo de RLM fue menos apto para aplicarse en la determinación del nivel de ácidos grasos dentro de este análisis. El error estándar de calibración (SEC) del modelo de AGL fue de 0,658, con una desviación de 0,126 y un error estándar de predicción (SEP) de 0,71.

Los dos modelos de este estudio produjeron resultados más rápidos con costos menores en comparación

con los análisis manuales de laboratorio. El modelo de predicción de CA mostró buena exactitud, mientras que el modelo de AGL tuvo un desempeño deficiente. Sin embargo, tiene la ventaja de no dañar las muestras después de la medición. Otra ventaja de este sistema fue que permitió una medición no destructiva del CA y los AGL de los RFF directamente en el sitio, dado que el sistema es portátil y se puede llevar al lugar de la cosecha del área del cultivo. Como los RFF se pueden clasificar directamente en el sitio de la cosecha, solo los racimos que cumplen los requisitos de calidad se transportarán a las plantas de beneficio y esto, a su vez, reduce los costos del transporte de los racimos no adecuados.

Conclusión

En esta investigación se elaboró un análisis de visión artificial no destructivo para evaluar la madurez y la calidad de los RFF de palma de aceite para su aplicación en campo. El sistema muestra buena movilidad y produce directamente resultados en las operaciones *in situ*. El sistema se compone de una cámara de inspección, una cámara fotográfica y una computadora. En la clasificación de madurez de los RFF se empleó un análisis discriminado para producir una función discriminante canónica. En cuanto al modelado del contenido de aceite y del nivel de ácidos grasos libres, se utilizó un análisis de regresión múltiple. Empleando 90 muestras, el sistema clasificó correctamente la madurez de 85 % de ellas. Se utilizó una curva ROC para evaluar la exactitud de la clasificación, que demostró que el modelo separó las clases de manera significativa. El modelo de predicción de contenido de aceite produjo un buen desempeño, con un R^2 de

0,931 y un SEP de 0,821. Por otro lado, el modelo de predicción de ácidos grasos libres mostró un desempeño deficiente con un R^2 de 0,26 y un SEP de 0,71 en desviación y error estándar de predicción (SEP), respectivamente. El sistema arrojó resultados con mayor rapidez y menor costo en comparación con los análisis manuales de laboratorio. Además, ofrece las ventajas de mediciones no destructivas que se pueden realizar en el sitio, con lo que se reduce el trabajo y el costo de transportar los RFF no apropiados a las plantas de beneficio.

Agradecimientos

Esta investigación contó con el apoyo del Instituto Asiático de Tecnología en Tailandia y fue financiado parcialmente por la Dirección General de Educación Superior (DIKTI) de Indonesia. Los autores desean agradecer el apoyo recibido de la Compañía Indonesia de Palma de Aceite (PTPN VIII).

Referencias

- Abbas, Z. (1994). A Micro strip Sensor for Determination of Harvesting time for Oil Palm fruits. Tesis, Universiti Putra Malaysia.
- Abdullah, M.Z., Guan, L.C., Mohd, Azemi B.M.N. (2001). Stepwise Discriminant Analysis For Colour Grading Of Oil Palm Using Machine Vision System. *Trans IChemE*, Vol. 79, Parte C, Diciembre de 2001.
- Abdullah, M. Z., Guan, L. C., Mohamed, A. M. D., Noor, M. A. M. (2002). Color vision system for ripeness inspection of oil palm *Elaeis guineensis*. *Journal of Food Processing Preservation*, 26: 213-235.
- Alfatni, M.S.M., Shariff, A.R., Shafri, H.Z.M., Saaed, O.M.B., Eshanta, O.M. (2008). Oil palm fruit bunch grading using red, green and blue digital number. *J. Applied Sciences*, vol. 8, no. 8: 1444-1452, 2008.
- AOCS (2004). *Official methods and recommended practices of the American Oil Chemists Society. Sampling and analysis of commercial fats and oil*. Champaign. EE. UU.: American Oil Chemists Society.
- Ditjenbun (2012). Oil Palm Industry in the first Semester 2012. Dirección General de Cultivos, Ministerio de Agricultura, República de Indonesia.
- Flingoh, Ch., Oh y Zukarinah, Kamurind (1989). Measurement Palm Mesocarp Oil Content by Nuclear Magnetic Resonance Spectroscopy. Porim. Conferencia Internacional sobre Desarrollo de Aceite de Palma (pp. 238-241). Kuala Lumpur, Malasia.
- Ghazalli, K.N.A.B. (2010). Tesis. Palm Oil Classification Using RGB andFuzzy.

- Hazir, M.H.M., Shariff, A.R.M. (2011). Oil Palm Physical and Optical Characteristics from Two Different Planting Materials. *Research Journal of Applied Sciences, Engineering and Technology*, 3(9): 953-962, 2011.
- Hudzari M.R., Ishak, W., I.W., Abd, Rahman, R., Md. Nasir, S., Mohd. Haniff, H. (2009). Development of Image Based Modeling for Determination of Oil Content and Days Estimation for Harvesting of FFB. *International Journal of Food Engineering*, Vol. 5, Ed. 1, artículo 1.
- Hudzari, R.M., Ishak, W.I.W., Noorman, M.M. (2010). Parameter Acceptance of Software Development for Oil Palm Fruit Maturity Prediction. *Journal of Software Engineering*, 2010.
- Idris, O., M.Ashhar, K., M.Haniff, H., & M. Basri, W. (2003). Colour Meter for Measuring Fruit Ripeness. MPOB Information Series: 195.
- IOPRI (1997). Pengolahan kelapa sawit dan pengelolaan limbah pabrik kelapa sawit. Tim standarisasi pengolahan kelapa sawit. Indonesian Oil Palm Research Institute (IOPRI). Versión-4/S-1/PIRBUN/1997. Direktorat jendral perkebunan. Indonesia.
- Ismail, W. I. W., Bardaie, M. Z., Hamid, A.M.A. (2000). Optical Properties For Mechanical Harvesting Of Oil Palm FFB. *Journal of Oil Palm Research*, Vol. 12, No. 2: 38-45.
- Ismail, W.I.W., Hudzari, R.M. (2010). Outdoor color recognition system for oil palm fresh fruit bunches (FFB). *International Journal of Machine Intelligence*, Vol. 2, ed. 1, 2010: 01-10.
- Ismail, W.I.W., Razali, M.H. (2010). Hue Optical Properties to Model Oil Palm Fresh Fruit Bunches Maturity Index. Proceeding. The International Multi-Conference on Complexity, Informatics and Cybernetics: IMCIC 2010, Instituto Internacional de Informática y Sistemica.
- Jaafar, R., Jamil, N., Jaffar, A., Abdullah, B. (2009). Image analysis of Fresh Fruit Bunches (FFB) using low cost vision system. Proc. Conferencia Internacional en Avances de Ingeniería Mecánica, pp. 20-25, julio de 2009.
- Jaffar, A., Jaafar, R., Jamil, N., Low, C. Y., Abdullah, B. (2009). Photogrammetric Grading of Oil Palm Fresh Fruit Bunches. *International Journal of Mechanical & Mechatronics Engineering IJMME*, Vol. 9, N.º 10.
- Jamil, N., Mohamed, A., Abdullah, S. (2009). Automated Grading of Palm Oil Fresh Fruit Bunches (FFB) using Neuro-Fuzzy Technique. Conferencia Internacional sobre Soft Computing y Reconocimiento de Patrones, pp. 245-249.
- Junkwon, P., Takigawa, T., Okamoto, H., Hasegawa, H., Koike, M., Sakai, K., Siruntawinetti, J., Chaeychomsri, W., Vanavichit, A., Tittinuchanon, P., Bahalayodhin, B. (2009). Hyperspectral imaging for nondestructive determination of internal qualities for oil palm (*Elaeis guineensis* Jacq. var. tenera). *Investigación de Información Agrícola*, 18(3): 130-141.
- NSAI (2006). Indonesian National Standard, National Standardization Agency of Indonesia, Badan Standardisasi Nasional, Yakarta, Indonesia.
- Nureize, A., Watada, J. (2008). A Fuzzy Regression Approach to Hierarchical Evaluation Model for Oil Palm Grading. *Actas de la IEEE de 2008*. IEEM.
- Omar, I., Khalid, M. A., Harun, M. H., Wahid, M. B. (2003). Color meter for Measuring fruit ripeness. MPOB information series. MPOB TT N.º 182, junio.
- Rashid, S., Nor, A., Adnan, R.M., Shattri, M., Rohaya, H., Roop, G. (2004). Correlation Between Oil Content and DN Values. Department of Biological and Agriculture, Universiti Putra Malaysia, GISdevelopment.net.
- Razali, M. H., Ismail, W. I. W., Ramli, A. R., Sulaiman, N., Harun, M. H. B. (2011). Technique on simulation for real time oil palm fruits maturity prediction. *African Journal of Agricultural Research*, Vol. 6(7): 1823-1830.
- Roseleena, J., Nursuriati, J., Ahmed, J., Low, C. Y. (2011). Assessment of palm oil fresh fruit bunches using photogrammetric grading system. *International Food Research Journal*, 18(3).

- Saeed, O.M.B, Sankaran, S., Shariff, A.R.M, Shafri, H.Z.M, Ehsani, R., Alfatni, M.S., Hazir, M.H.M. (2012). Classification of oil palm fresh fruit bunches based on their maturity using portable four-band sensor system. *Computers and Electronics in Agriculture*, 82 (2012): 55-60.
- Shaarani, S. M. D., Cardenas-Blanco, A., Amin, M. H. G., Soon, N. G., Hall, L. D. (2010). Monitoring Development and Ripeness of Oil Palm Fruit (*Elaeis guineensis*) by MRI and Bulk NMR. *International Journal Of Agriculture & Biology*.
- Tan, Y.A., K.W. Low, C.K. Lee, K.S. Low (2010). Imaging technique for quantification of oil palm fruit ripeness and oil content. *Euro. J. Lipid Sci. Technol.*, 112(8): 838-843.
- Yeow, Y.K., Abbas, Z., Khalid, K. (2010). Application of Microwave Moisture Sensor for Determination of Oil Palm Fruit Ripeness. *Measurement Science Review*, Vol. 10, N.º 1.

Lecturas adicionales

- Makky, Muhammad, Soni, Peeyush, and Vilas M. Salokhe (2014). Automatic Non-destructive Quality Inspection System for Oil Palm Fruits. *International Agrophysics*, 28(3): 319-329.
- Makky, Muhammad, Soni, Peeyush (2014). In-situ Quality Assessment of Intact Oil Palm Fresh Fruit Bunches using Rapid Portable Non-contact and Non-destructive Approach. *Journal of Food Engineering*, 120: 248-259. Elsevier.
- Makky, Muhammad, Soni, Peeyush (2013). Towards Sustainable Green Production: Exploring Automated Grading for Oil Palm Fresh Fruit Bunches (FFB) Using Machine Vision and Spectral Analysis. *International Journal on Advanced Science, Engineering and Information Technology*, Vol. 3(1):1-6. Indonesian Society for Knowledge and Human Development.
- Makky, Muhammad, Soni, Peeyush (2013). Development of an Automatic Grading Machine for Oil Palm Fresh Fruits Bunches (FFBs) based on Machine Vision. *Computers and Electronics in Agriculture*, 93:129-139. Elsevier.