

Prediksi Kandungan Lignin pada Dedak Padi Bercampur Sekam Menggunakan Tekstur Statistik dan KNN

Estimation of Lignin Content in Rice Bran Mixed with Husk Using Statistical Textures and KNN

EYLIEN DESY NOVITA¹, AZIZ KUSTIYO^{2*}, ANURAGA JAYANEGARA³, TOTO HARYANTO², HARI AGUNG ADRIANTO²

Abstrak

Pemalsuan dedak padi terjadi cukup tinggi karena harga dedak padi yang mahal. Kualitas dedak padi yang bercampur sekam dapat menurun karena kandungan serat kasar dan lignin bersifat anti-nutrisi. Kandungan lignin dapat diestimasi dengan tekstur citra dedak padi yang bercampur sekam. Penelitian ini bertujuan untuk melakukan analisis tekstur pada citra dedak padi yang bercampur sekam menggunakan metode ekstraksi ciri *run-length* dengan klasifikasi *k-nearest neighbour* (KNN). Citra dedak padi yang bercampur sekam diakuisisi dengan mikroskop digital Dino Capture dengan perbesaran sebesar 200 kali. Citra yang dihasilkan berukuran 640×480 piksel dengan format bitmap. Praproses dilakukan dengan mengubah citra RGB ke dalam *grayscale*, kemudian dilakukan *image enhancement* menggunakan *histogram equalization*. Data uji dan data latih ditentukan menggunakan *5-fold cross validation* dengan 3 ulangan. Hasil KNN dengan 7 ciri *run-length* menghasilkan akurasi terbaik sebesar 74.55% pada sudut 135° dan $k = 5$.

Kata Kunci: dedak padi, *k-nearest neighbour*, lignin, *run-length*, sekam

Abstract

Adulteration in rice bran happens quite frequently due to the expensive price of rice bran. Mixing the rice bran with husk could decrease the rice bran quality because the crude fiber and lignin content in the husk are anti-nutrients. Lignin content can be estimated by the texture of rice bran mixed with husk image. This study aims to analyze the texture of rice bran mixed with husk image using the run-length feature extraction method with k-nearest neighbor (KNN) classification. The images of rice bran mixed with husk were taken using Dino Capture digital microscope with 200 times magnification. The images were generated with a spatial resolution of 640×480 pixels in a bitmap format. Those images were converted from RGB into grayscale in preprocessing phase, which was then enhanced using histogram equalization as an image enhancement method. The training and testing were determined using 5-fold cross-validation with three repetitions. The result of KNN classification with seven features shows the highest accuracy at 74.55%.

Keywords: husk, *k-nearest neighbour*, lignin, rice bran, *run-length*

PENDAHULUAN

Pakan merupakan faktor lingkungan terbesar yang menjadi faktor penentu perbedaan produksi ternak. Pakan merupakan semua bahan yang dapat dimakan ternak, sedangkan ransum adalah sejumlah pakan/campuran pakan untuk ternak yang dijatahkan dalam sehari (Ridla *et al.* 2015). Untuk menjamin mutu pakan, pemerintah telah menetapkan Standar Nasional Indonesia (SNI) atau Persyaratan Teknis Minimal (PTM) untuk kesesuaian pakan. Namun demikian,

¹Alumni Departemen Ilmu Komputer FMIPA IPB;

²Departemen Ilmu Komputer, FMIPA, IPB;

³Departemen Ilmu Nutrisi dan Teknologi Pakan, Fakultas Peternakan, IPB;

*Penulis Korespondensi: Tel/Faks: 0251-8625584; Surel:azizku@apps.ipb.ac.id

terdapat faktor-faktor yang menyebabkan terjadinya degradasi mutu bahan pakan yaitu terjadinya kerusakan pakan itu sendiri atau adanya bahan pencemar. Faktor yang paling banyak dijumpai di lapangan ialah terjadinya pemalsuan pakan. Prinsip utama yang digunakan dalam pemalsuan pakan adalah dengan mengganti sebagian bahan utama dengan mencampurkannya dengan bahan lain (Rusyidi 2014). Meski bahan lain tersebut memiliki karakteristik yang hampir sama dengan bahan-bahan baku yang dipalsukan, namun tetap akan menurunkan kadar nutrisi dalam pakan (Ahsani 2006). Hal ini tentunya melanggar peraturan tentang perlindungan konsumen yang tertuang dalam Undang-Undang Republik Indonesia nomor 8 tahun 1999 (Kemensetneg 1999).

Menurut Kushartono (2000), dedak, jagung, tepung ikan dan bungkil kedelai merupakan bahan pakan yang lazim digunakan dalam pembuatan ransum. Dedak padi merupakan hasil sisa dari proses penggilingan atau penumbukan padi. Dedak dibedakan berdasarkan kualitasnya menjadi tiga jenis yaitu bekatul, dedak halus biasa, dan dedak kasar. Bekatul adalah sisa penumbukan yang dihasilkan bersama dengan penyosohan beras (slep beras) yang bagian terbesarnya berupa selaput beras, bahan lembaga (menir), dan sedikit mengandung kulit sekam sehingga dapat dijadikan bahan pakan yang baik untuk ternak. Dedak halus biasa merupakan hasil sisa penumbukan padi secara tradisional, banyak mengandung selaput beras, pecahan lembaga beras, dan komponen sekam. Dedak kasar sebagian besar berupa sekam halus dan bercampur dengan sedikit lembaga beras. Dedak kasar kurang baik bagi ternak karena daya cerna yang rendah.

Trouw Nutrition Indonesia menganalisis bahan pakan secara berkala dan salah satu hasilnya memperlihatkan kualitas dedak yang sangat tidak stabil (Sidiq dan Wardani 2014). Kualitas dedak padi yang bervariasi kemungkinan disebabkan pemalsuan dedak dengan sekam dan kapur atau pasir. Kualitas dedak padi yang dicampur dengan sekam menurun karena meningkatnya kandungan serat kasar dan adanya lignin yang bersifat antinutrisi (Maulana 2007). Pemalsuan yang tidak teridentifikasi pada dedak menyebabkan besarnya masalah pada pencernaan hewan ternak dan mempersulit formulasi pakan (Sidiq dan Wardani 2014). Kualitas dedak padi dapat diuji secara fisik dengan pengamatan panca indera (dilihat, dicium dan diraba), uji apung/*floating*, uji dengan larutan *Phloroglucinol*, atau menghitung berat jenis/*bulk density* dedak padi (Mahargya 2019).

Sekam padi mengandung sekitar 20% lignin (Ma'ruf *et al.* 2017) yang merupakan polimer alami yang sangat rumit (Sun 2020). Secara umum lignin terdapat di berbagai bagian tumbuhan yang berkayu (*woody xylem*) dan konsentrasinya tinggi di-*middle lamella* (Sjöström 1993). Karena sekam padi berkayu dan kasar, sedangkan dedak lebih halus, pemalsuan dedak padi yang bercampur sekam dapat dilihat berdasarkan teksturnya. Estimasi kandungan lignin dapat diketahui dengan tekstur citra sekam yang terdapat pada dedak padi karena banyaknya kandungan lignin berbanding lurus dengan banyaknya campuran sekam. Estimasi tersebut dapat dilakukan dengan metode klasifikasi berdasarkan tekstur citra dedak padi bercampur sekam. Penggunaan metode ini dapat digunakan sebagai prediksi awal terhadap metode uji fisik kualitas dedak padi berdasarkan pengamatan panca indera (Mahargya 2019).

Analisis tekstur merupakan bagian dari pengolahan citra digital yang berkaitan dengan tekstur citra. Penelitian terkait analisis tekstur untuk prediksi kandungan lignin telah dilakukan oleh Yuliati (2016). Ciri yang digunakan oleh Yuliati (2016) adalah delapan tekstur statistik yang diturunkan dari *Gray-Level Co-occurrence Matrix* (GLCM). Metode klasifikasi yang digunakan dalam penelitian tersebut adalah KNN dan menghasilkan akurasi sebesar 71.82%. Penelitian lain terkait KNN dan GLCM dilakukan oleh Noordama (2014) berupa identifikasi varietas *Durio zibethinus* berdasarkan sebaran trikoma daun. Penelitian tersebut melakukan ekstraksi ciri sebanyak 11 ciri GLCM dan mendapatkan akurasi sebesar 78%.

Penelitian lain terkait analisis tekstur dilakukan oleh Kairuddin dan Mahmud (2017) menggunakan metode ekstraksi ciri *Gray-Level Run-length Matrix* (GLRLM). Penelitian tersebut menunjukkan peran ekstraksi ciri GLRLM dalam penentuan karakteristik jaringan ginjal yang sehat. Penelitian lain terkait metode GLRLM ini antara lain dilakukan Wardani *et*

al. (2020) untuk mendeteksi gangguan pada mata pada penderita diabetes. Haji dan Yousif (2019) menggunakan ekstraksi ciri GLRLM untuk melakukan skrining keganasan *thyroid nodule*. Kedua penelitian tersebut menghasilkan akurasi klasifikasi lebih dari 90%.

Penelitian-penelitian berikut menunjukkan bahwa metode ekstraksi ciri GLRLM lebih baik dibandingkan metode GLCM. Singh (2016) membandingkan 4 ciri GLCM dan 4 ciri GLRLM dalam klasifikasi butiran-butiran beras. Untuk metode klasifikasi KNN, 4 ciri dari GLRLM menghasilkan akurasi sebesar 99.75%, sedangkan 4 ciri dari GLCM menghasilkan akurasi 89%. Sari *et al.* (2021) melakukan klasifikasi citra digital 7 jenis kura-kura Sumatera menggunakan jaringan syaraf tiruan berdasarkan 4 ciri GLCM dan 5 ciri GLRLM. Identifikasi jenis kura-kura tersebut menghasilkan akurasi 75% berdasarkan ciri GLCM dan 79.5% berdasarkan ciri GLRLM. Telaumbanua *et al.* (2021) menggunakan ciri dari GLCM dan GLRLM untuk identifikasi sampah dengan metode klasifikasi *improved* KNN. Sampah yang diidentifikasi terdiri dari kardus, kaca, besi, kertas, dan plastik. Penelitian ini menghasilkan akurasi sebesar 90.4% untuk klasifikasi berdasarkan ciri dari GLRLM dan 80.8% untuk ciri dari GLCM.

Berdasarkan penelitian-penelitian tersebut, penelitian ini bertujuan untuk menduga kandungan lignin pada dedak bercampur sekam. Pendugaan kandungan lignin dilakukan menggunakan analisis tekstur pada citra dedak padi yang bercampur sekam dengan metode ekstraksi ciri GLRLM dan klasifikasi KNN. Penelitian ini diharapkan dapat membantu melakukan identifikasi pemalsuan dedak padi yang bercampur sekam berdasarkan kandungan lignin.

METODE

Data

Uji kadar lignin menggunakan analisis Van Soest (Ridla *et al.* 2015) dilakukan di Laboratorium Ilmu dan Teknologi Pakan, Departemen Ilmu Nutrisi dan Teknologi Pakan, Fakultas Peternakan, Institut Pertanian Bogor untuk mengetahui kadar lignin dalam dedak. Uji tersebut diterapkan terhadap campuran dedak dan sekam dengan perbandingan tertentu. Perbandingan kandungan sekam dan dedak yang digunakan dalam penelitian ini disajikan pada Tabel 1. Kelas 0 merupakan dedak yang tidak dicampur sekam, sedangkan kelas 10 hanya berupa sekam. Sembilan kelas di antara kelas 0 dan kelas 10 merupakan kelas-kelas dengan variasi perbandingan dedak dan sekam dengan total berat 10 gram.

Citra yang digunakan dalam penelitian ini adalah citra dari campuran dedak dan sekam dengan perbandingan seperti pada Tabel 1. Citra tersebut diakuisisi menggunakan mikroskop digital Dino Capture (<https://www.dinolite.us/en/products/digital-microscopes/usb>) dengan perbesaran 200 kali. Citra yang dihasilkan berukuran 640×480 piksel dengan format *bitmap*. Setiap kelas diambil sebanyak 10 citra.

Metode

Tahapan yang dilakukan pada penelitian disajikan pada Gambar 1. Penelitian dimulai dengan praproses data, ekstraksi ciri, pembagian data, klasifikasi, dan diakhiri dengan perhitungan akurasi.

Tahap praproses yang dilakukan yaitu mengubah citra RGB ke dalam *grayscale* dengan tujuan untuk menyederhanakan piksel dari 3 layer menjadi 1 layer matriks. Untuk mengubah citra RGB menjadi citra *grayscale* digunakan rumus yang dijelaskan pada Persamaan 1 (Jacobsen 2012). Kemudian, hasil citra *grayscale* dilakukan *image enhancement* atau perbaikan kontras menggunakan *histogram equalization* yang dijelaskan pada Persamaan 2 (Gonzales dan Woods 2018).

$$Grayscale = 0.299 Red + 0.587 Green + 0.114 Blue \tag{1}$$

$$S_k = T(r_k) = \frac{L-1}{MN} \sum_{j=0}^k n_j \tag{2}$$

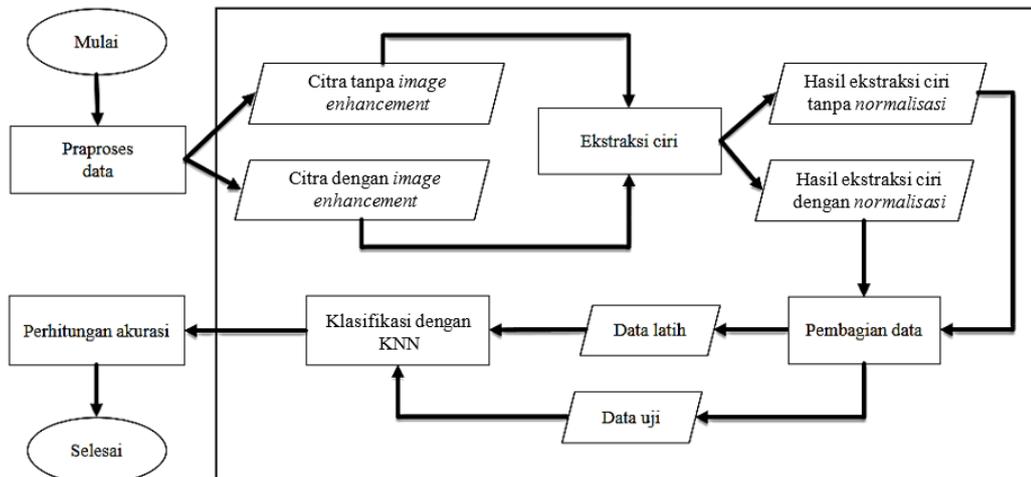
keterangan:

- S_k = hasil citra *image enhancement*
- $T(r_k)$ = nilai input tingkat keabuan k
- k = tingkat abu-abu diskrit $[0, L-1]$
- L = jumlah tingkat abu-abu
- MN = total jumlah piksel
- n_j = jumlah piksel yang memiliki derajat keabuan j

Ekstraksi ciri yang digunakan adalah metode ekstraksi ciri tekstur statistik berupa GLRLM. Metode tersebut menggunakan distribusi piksel dengan intensitas yang sama secara berurutan dalam satu arah tertentu. Untuk menentukan arah tersebut terdapat empat orientasi sudut yang dapat dipilih yaitu 0° , 45° , 90° , dan 135° (Chaki dan Dey 2020). Adapun ciri dari tekstur dijelaskan pada Tabel 2 dan Persamaan 3–13 (Galloway 1975; Chu *et al.* 1990; Dasarathy dan Holder 1991; Tang 1998).

Tabel 1 Perbandingan kandungan sekam dan dedak

Kelas	Kandungan sekam (gram)	Kandungan dedak (gram)
0	0	10
1	1	9
2	2	8
3	3	7
4	4	6
5	5	5
6	6	4
7	7	3
8	8	2
9	9	1
10	10	0



Gambar 1 Tahapan Penelitian.

Tabel 2 Ciri tekstur yang digunakan

Kelompok	Ciri yang digunakan
Galloway (1975)	1 <i>Short Run Emphasis (SRE)</i>
	2 <i>Long Run Emphasis (LRE)</i>
	3 <i>Grey-Level Nonuniformity (GLN)</i>
	4 <i>Run-length Nonuniformity (RLN)</i>
	5 <i>Run Percentage (RP)</i>
Chu et al. (1990)	6 <i>Low Gray-Level Run Emphasis (LGLRE)</i>
	7 <i>High Gray-Level Run Emphasis (HGLRE)</i>
	8 <i>Short Run Low Gray-Level Emphasis (SRLGLE)</i>
Dasarathy & Holder (1991)	9 <i>Short Run High Gray-Level Emphasis (SRHGLE)</i>
	10 <i>Long Run Low Gray-Level Emphasis (LRLGLE)</i>
	11 <i>Long Run High Gray-Level Emphasis (LRHGLE)</i>

$$SRE = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i,j)}{j^2} = \frac{1}{n_r} \sum_{j=1}^N \frac{p_r(j)}{j^2} \quad (3)$$

$$LRE = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N p(i,j) \cdot j^2 = \frac{1}{n_r} \sum_{j=1}^N p_r(j) \cdot j^2 \quad (4)$$

$$GLN = \frac{1}{n_r} \sum_{i=1}^M \left(\sum_{j=1}^N p(i,j) \right)^2 = \frac{1}{n_r} \sum_{i=1}^M p_g(i)^2 \quad (5)$$

$$RLN = \frac{1}{n_r} \sum_{j=1}^N \left(\sum_{i=1}^M p(i,j) \right)^2 = \frac{1}{n_r} \sum_{j=1}^N p_r(j)^2 \quad (6)$$

$$RP = \frac{n_r}{n_p} \quad (7)$$

$$LGLRE = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i,j)}{i^2} = \frac{1}{n_r} \sum_{i=1}^M \frac{p_g(i)}{i^2} \quad (8)$$

$$HGLRE = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N p(i,j) \cdot i^2 = \frac{1}{n_r} \sum_{i=1}^M p_g(i) \cdot i^2 \quad (9)$$

$$SRLGLE = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i,j)}{i^2 \cdot j^2} \quad (10)$$

$$SRHGLE = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i,j) \cdot j^2}{i^2} \quad (11)$$

$$LRLGLE = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i,j) \cdot j^2}{i^2} \quad (12)$$

$$\text{LRHGLE} = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N p(i,j) \cdot i^2 \cdot j^2 \quad (13)$$

keterangan:

- $p(i,j)$ = piksel keabuan dengan nilai keabuan (i) dan nilai *Run-length* (j)
 M = nilai level keabuan
 N = maksimum *Run-length*
 n_r = jumlah *Run-length* pada arah tertentu
 n_p = jumlah piksel dalam citra
 p_g = total *Run-length* berdasarkan nilai derajat keabuannya (*grayscale*)
 p_r = total *Run-length* berdasarkan banyak urutannya (*Run-length*)

Setelah dianalisis kembali, hasil perhitungan *Run-length* memiliki selang yang berbeda-beda. Oleh karena itu, dilakukan proses normalisasi terlebih dahulu. Normalisasi dilakukan menggunakan Persamaan 14 (Han *et al.* 2011) dan menghasilkan data baru yang bernilai antara 0 dan 1.

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (14)$$

keterangan:

- X' = nilai normalisasi
 X = nilai asli
 X_{\max} = nilai maksimum
 X_{\min} = nilai minimum

Pada penelitian ini, percobaan dilakukan untuk mengetahui pengaruh *image enhancement* dan normalisasi ciri terhadap akurasi klasifikasi KNN. Klasifikasi dilakukan dengan dan tanpa *image enhancement* kemudian dengan dan tanpa normalisasi. Secara umum kedua perlakuan tersebut akan meningkatkan akurasi klasifikasi, namun demikian, dengan percobaan akan diketahui besarnya peningkatan akurasi klasifikasi. Percobaan ini dilakukan setelah diperoleh ciri tekstur GLRLM.

Setelah melakukan tahap ekstraksi ciri, hasil yang diperoleh selanjutnya menggunakan *k-fold cross validation* dibagi menjadi data latih dan data uji (Marcot dan Hanea 2021). Data uji diperoleh dengan membagi seluruh data (110 citra) dengan $k=5$ sehingga terdapat 22 data citra untuk data uji dan 88 data citra untuk data latih. Skema pembagian data latih dan data uji dapat dilihat pada Gambar 2. Pada penelitian ini, skema *5-fold cross validation* diulang sebanyak 3 kali dengan komposisi yang berbeda. Sebagai contoh, 2 data uji kelas 0 pada ulangan 1 adalah citra ke-1 dan ke-10, ulangan ke-2 menggunakan citra ke-1 dan ke-2, dan ulangan ke-3 menggunakan citra ke-4 dan ke-5.

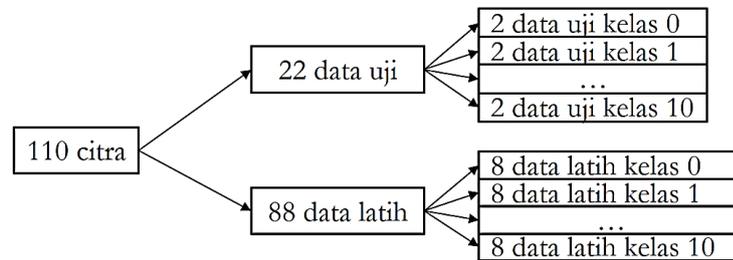
Metode klasifikasi yang digunakan setelah pembagian data uji dan data latih adalah klasifikasi KNN. Tujuan algoritme ini yaitu mengklasifikasikan data uji berdasarkan atribut data latih. Cara kerja algoritme ini didasarkan pada jarak minimum data uji terhadap k tetangga terdekat (k data latih terdekat) yang telah ditetapkan (Evangelia 2000). Untuk mengukur jarak antara data uji dengan data latih digunakan jarak *Euclidean* seperti pada Persamaan 15.

$$d(x,y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (15)$$

keterangan:

- $d(x,y)$ = jarak *Euclidean*
 x_i = data uji atribut ke- i
 y_i = data latih atribut ke- i
 n = banyaknya atribut data

Salah satu cara untuk mengevaluasi ketepatan hasil klasifikasi adalah menggunakan *confusion matrix*. Kesalahan klasifikasi per kelas dapat dilihat dari *confusion matrix*. Hasil dari tabel *confusion matrix* selanjutnya dapat digunakan untuk menghitung nilai akurasi (Tharwat 2020). Perhitungan akurasi diperlukan untuk evaluasi hasil klasifikasi KNN. Perhitungan akurasi menggunakan Persamaan 16. Akurasi yang didapatkan tersebut merupakan rata-rata dari setiap *fold* ke i ($i = 1, 2, 3, 4, 5$).



Gambar 2 Skema pembagian data.

$$\text{Akurasi} = \frac{\sum \text{citra benar}}{\sum \text{citra data uji}} \times 100\% \quad (16)$$

Setelah menghitung rata-rata akurasi KNN berdasarkan 11 ciri tekstur statistik GLRLM, selanjutnya dilakukan proses seleksi ciri. Seperti yang telah diuraikan di atas, persamaan-persamaan untuk menghitung 11 ciri tersebut terdiri dari 3 kelompok yaitu dari Galloway (1975), Chu *et al.* (1990), serta Dasarathy dan Holder (1991). Pada penelitian ini akan dihitung rata-rata akurasi KNN berdasar ciri dari setiap kelompok dan dari gabungan dua kelompok untuk dibandingkan dengan rata-rata akurasi KNN dengan gabungan ketiga kelompok (11 ciri).

HASIL DAN PEMBAHASAN

Kandungan Lignin pada Campuran Dedak dan Sekam

Hasil analisis Van Soest untuk mengetahui kadar lignin dalam campuran dedak dan sekam disajikan pada Tabel 3. Kandungan lignin terendah sebesar 10.19% terdapat pada dedak tanpa sekam (kelas 0), sedangkan kandungan lignin tertinggi sebesar 16.16% terdapat pada sekam tanpa dedak (kelas 10). Tiga kelas pertama memiliki kandungan lignin kurang dari 11% dan tiga kelas terakhir memiliki kandungan lignin lebih dari 16%.

Hasil akuisisi citra campuran dedak dan sekam pada awalnya berukuran 640×480 piksel. Contoh citra yang telah diakuisi disajikan pada Gambar 3 yang merupakan citra kelas 0 dan Gambar 4 yang merupakan citra kelas 1 sampai dengan kelas 10. Secara visual, citra kelas 0 (Gambar 3) sampai dengan kelas 3 (Gambar 4c) memiliki kemiripan berupa tekstur yang lembut. Citra kelas 8 (Gambar 4h) sampai dengan kelas 10 (Gambar 4j) memiliki kemiripan berupa tesktur yang kasar.

Praproses Data

Pada tahap praproses data, data sebanyak 110 citra diubah ke dalam bentuk *grayscale*. Kemudian hasil citra *grayscale* dilakukan *image enhancement* atau perbaikan kontras untuk meningkatkan akurasi menggunakan *histogram equalization* seperti pada Gambar 5. Hasil *histogram equalization* menunjukkan perbedaan kontras yang lebih tajam sebelum dilakukan praproses tersebut (gambar paling kanan).

Penentuan Banyaknya Kelas untuk Klasifikasi Menggunakan KNN

Berdasarkan kandungan lignin pada Tabel 3, terdapat kelas-kelas dengan nilai kandungan lignin yang tidak berbeda jauh. Oleh karena itu dilakukan penggabungan di antara kelas-kelas tersebut sebagai berikut:

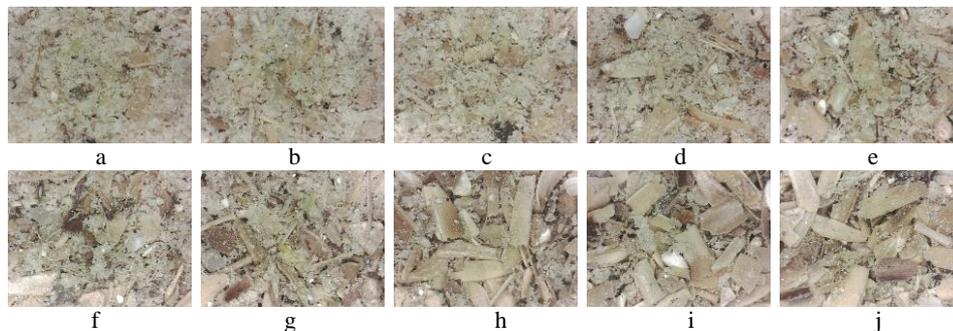
- Kelas 0, 1, dan 2 dengan kadar lignin 10.0 – 11.5% dan selanjutnya disebut sebagai kelas 1
- Kelas 3 dan 4 dengan kadar lignin 11.5 – 13.0% dan selanjutnya disebut sebagai kelas 2
- Kelas 5, 6, dan 7 dengan kadar lignin 13.0 – 15.5% dan selanjutnya disebut sebagai kelas 3
- Kelas 8, 9, dan 10 dengan kadar lignin 15.5 - 17.0% dan selanjutnya disebut sebagai kelas 4.

Tabel 3 Kandungan lignin pada berbagai perbandingan kandungan sekam dan dedak

Kelas	Kandungan sekam (gram)	Kandungan dedak (gram)	Lignin (%)
0	0	10	10.19
1	1	9	10.35
2	2	8	10.59
3	3	7	12.31
4	4	6	12.81
5	5	5	13.44
6	6	4	13.50
7	7	3	14.31
8	8	2	16.00
9	9	1	16.07
10	10	0	16.16



Gambar 3 Contoh citra kelas 0 (dedak tanpa campuran sekam).



Gambar 4 Contoh citra kelas 1 sampai dengan kelas 10 (berturut turut dari a sampai dengan j).

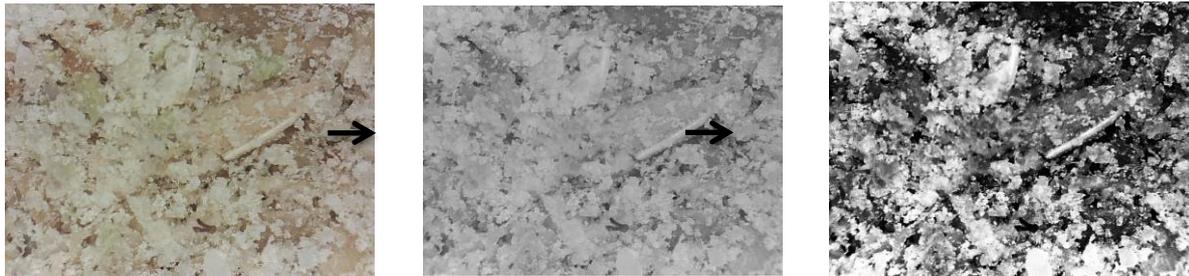
Pengaruh *Image Enhancement* dan Normalisasi Data

Untuk mengetahui pengaruh *image enhancement*, dilakukan percobaan klasifikasi KNN berdasarkan ciri tekstur GLRLM dari citra hasil akuisisi dengan dan tanpa *image enhancement*. Hasil percobaan menunjukkan bahwa *image enhancement* menggunakan *histogram equalization* menghasilkan peningkatan akurasi sekitar 9% yaitu dari 56.36% menjadi 65.45%. Dengan demikian, *image enhancement* perlu diterapkan dalam penelitian ini.

Kemudian, untuk mengetahui pengaruh normalisasi ciri, dilakukan percobaan klasifikasi KNN berdasarkan ciri tekstur GLRLM dari citra hasil akuisisi dengan dan tanpa normalisasi data. Citra yang digunakan merupakan citra hasil *image enhancement*. Hasil percobaan menunjukkan bahwa normalisasi ciri meningkatkan akurasi sekitar 5% yaitu dari 65.45% menjadi 70.91%. Hal ini menunjukkan bahwa normalisasi data perlu dilakukan dalam klasifikasi berbasis tekstur citra menggunakan KNN.

Akurasi Klasifikasi KNN dari 3 Ulangan

Akurasi KNN dengan tiga ulangan disajikan pada Tabel 4. Nilai akurasi yang disajikan pada Tabel 4 adalah hasil rata-rata dari tiga ulangan. Berdasarkan hasil uji, sudut 30° tidak terdapat pola peningkatan akurasi dengan semakin tingginya nilai k pada KNN. Pada hasil uji dengan sudut 45°, semakin tinggi nilai k maka semakin tinggi rata-rata akurasi KNN. Terdapat pola yang sama pada sudut 90° dan 135°, dengan rata-rata akurasi tertinggi terjadi pada $k = 5$. Berdasarkan data dari tiga ulangan, rata-rata akurasi tertinggi dari KNN adalah sebesar 68.79% pada saat $k=5$. Dari seluruh skema *5-fold cross validation*, rata-rata akurasi tertinggi KNN adalah 70.91% yang dihasilkan dari ulangan 1, dengan sudut 135° dan $k=5$. KNN dengan skema inilah yang kemudian dianalisis lebih lanjut dengan seleksi ciri.



Gambar 5 Ilustrasi hasil praposes data.

Tabel 4 Akurasi KNN dengan 3 ulangan

Nilai k	<i>Mean ± sd (standar deviasi)</i>			
	Sudut 0° (%)	Sudut 45° (%)	Sudut 90° (%)	Sudut 135° (%)
$k=1$	57.27 ± 0.91	58.79 ± 1.39	62.12 ± 1.39	58.79 ± 1.39
$k=3$	60.61 ± 0.52	62.73 ± 2.41	62.73 ± 1.57	63.33 ± 1.05
$k=5$	63.94 ± 3.44	64.55 ± 1.82	66.36 ± 1.57	68.79 ± 2.92
$k=7$	63.03 ± 3.19	64.24 ± 2.78	63.03 ± 2.10	64.85 ± 1.39
$k=9$	60.61 ± 2.29	67.58 ± 1.89	65.76 ± 2.92	66.06 ± 2.62
$k=11$	63.03 ± 1.05	67.27 ± 1.57	63.64 ± 0.91	65.45 ± 0.91

Seleksi Fitur (Ciri)

Perbandingan rata-rata akurasi KNN berdasarkan kelompok ciri tekstur statistik disajikan pada Tabel 5. Ciri tekstur kelompok Galloway (1975) menunjukkan akurasi yang lebih tinggi dibanding dengan dua kelompok yang lain. Rata-rata akurasi KNN tertinggi sebesar 74.55% dihasilkan dari gabungan ciri kelompok Galloway (1975) dan Chu *et al.* (1990) dengan 7 ciri. Hasil tersebut lebih tinggi dibandingkan rata-rata akurasi KNN dengan 11 ciri (gabungan ketiga kelompok).

Evaluasi

Berdasarkan hasil seleksi fitur (Tabel 5), rata-rata akurasi KNN tertinggi adalah 74.55%. Hasil ini lebih baik dibandingkan rata-rata akurasi prediksi kandungan lignin berdasarkan ciri dari GLCM sebesar 71.82% (Yuliati 2016). Hasil ini juga mengonfirmasi hasil-hasil penelitian Singh (2016), Sari *et al.* (2021), dan Telaumbanua *et al.* (2021) yang menyatakan bahwa ekstraksi ciri dari GLRLM menghasilkan akurasi yang lebih tinggi dibandingkan ekstraksi ciri dari GLCM.

Selanjutnya, evaluasi dilakukan terhadap hasil tersebut untuk mengetahui kesalahan-kesalahan klasifikasi menggunakan *confusion matrix* (Tabel 6). Secara umum, sebagian besar kesalahan klasifikasi terjadi pada kelas terdekat. Sebagai contoh, kelas 1 (kandungan lignin 10.0 – 11.5%) diklasifikasi sebagai kelas 2 (kandungan lignin 11.5 - 13.0%) dan kelas 4 (kandungan lignin 15.5 – 17.0%) diklasifikasi sebagai kelas 3 (kandungan lignin 13.0 - 15.5%).

Hal ini kemungkinan disebabkan oleh masih adanya kemiripan antar citra dari 2 kelas yang berdekatan.

Mutu dedak padi sebagai bahan pakan ternak digolongkan menjadi mutu I, II, dan III. Kandungan serat kasar maksimum untuk mutu I sebesar 11%, mutu II 14%, dan mutu III 16% (BSN 2013). Berdasarkan Tabel 6 dan Tabel 3, kelas 1 dengan kandungan lignin terendah (10.0 – 11.5%) mewakili dedak mutu I, kelas 2 dan kelas 3 dengan kandungan lignin (11.5 – 15.5) mewakili dedak mutu II, sedangkan kelas 3 dengan kandungan lignin tertinggi (15.5 – 17.0%) mewakili mutu dedak III. Tabel 6 menunjukkan bahwa kesalahan prediksi dedak mutu II sebagai dedak mutu I sebanyak 5 dari 50 kasus, sedangkan kesalahan prediksi dedak mutu III sebagai dedak mutu II sebanyak 11 dari 30 kasus.

Tabel 5 Perbandingan rata-rata akurasi KNN berdasar kelompok ciri tekstur statistik

Kelompok	Ciri yang digunakan	Akurasi (%)
Galloway (1975)	SRE, LRE, GLN, RLN, RP	72.73
Chu <i>et al.</i> (1990)	LGLRE, HGLRE	42.73
Dasarathy & Holder (1991)	SRLGLE, SRHGLE, LRLGLE, LRHGLE	48.18
Galloway-Chu	SRE, LRE, GLN, RLN, RP, LGLRE, HGLRE	74.55
Galloway-Dasarathy & Holder	SRE, LRE, GLN, RLN, RP, SRLGLE, SRHGLE, LRLGLE, LRHGLE	68.18
Chu-Dasarathy & Holder	LGLRE, HGLRE, SRLGLE, SRHGLE, LRLGLE, LRHGLE	54.55
Galloway-Chu-Dasarathy & Holder	SRE, LRE, GLN, RLN, RP, LGLRE, HGLRE, SRLGLE, SRHGLE, LRLGLE, LRHGLE	70.91

Tabel 6 *Confusion matrix* hasil klasifikasi KNN

Kandungan lignin aktual (%)	Kandungan lignin prediksi (%)			
	10.0 – 11.5	11.5 – 13.0	13.0 – 15.5	15.5 – 17.0
10.0 – 11.5	29	1	0	0
11.5 – 13.0	4	14	2	0
13.0 – 15.5	1	4	21	4
15.5 – 17.0	1	2	9	18

SIMPULAN

Hasil penelitian menunjukkan bahwa penggunaan metode ekstraksi ciri tekstur statistik berupa *Gray-Level Run-Length Matrix* dan klasifikasi KNN dapat diterapkan untuk menduga kandungan lignin pada dedak padi bercampur sekam. Hasil klasifikasi KNN menggunakan 7 ciri menunjukkan akurasi yang cukup baik yaitu sebesar 74.55%. Namun demikian, hasil ini masih perlu ditingkatkan lagi karena kesalahan klasifikasi masih cukup besar pada kelas dengan kandungan lignin yang tinggi. Untuk penelitian berikutnya, perbaikan kinerja klasifikasi dapat dilakukan baik dari sisi ekstraksi ciri maupun algoritme klasifikasi yang digunakan.

DAFTAR PUSTAKA

- Ahsani E. 2006. Karakterisasi standar mikroskopis bahan pakan sumber protein (tepung ikan, bungkil kedelai, dan tepung daging dan tulang) sebagai metode alternatif pengujian kualitas bahan pakan [skripsi]. Bogor (ID): Institut Pertanian Bogor.
- [BSN] Badan Standardisasi Nasional. 2013. *Buletin Informasi SNI Terbaru Volume 1 No. 3, November 2013*. Jakarta (ID): BSN.
- Chaki J, Dey N. 2020. *Texture Feature Extraction Techniques for Image Recognition*. Singapore(SG): SpringerBriefs in Computational Intelligence.
- Chu A, Sehgal CM, Greenleaf JF. 1990. Use of gray value distribution of run-lengths for texture analysis. *Pattern Recognition Letter*. 11: 415–420.

- Dasarathy BR, Holder EB. 1991. Image characterizations based on joint gray-level run-length distributions. *Pattern Recognition Letter*. 12: 497–502.
- Evangelia M. 2000. *Supervised and Unsupervised Pattern Recognition: Feature Extraction and Computational Intelligence*. Florida(US): CRC Press LLC.
- Galloway MM. 1975. Texture analysis using gray level run-lengths. *Computer Graphics and Image Processing* 4: 172–179.
- Gonzales RC, Woods RE. 2018. *Digital Image Processing, 4th Ed*. New York(US): Pearson.
- Haji SO, Yousif RZ. 2019. A Novel Run-length based wavelet features for screening thyroid nodule malignancy. *Brazilian Archives of Biology and Technology*. 62: e19170821.
- Han J, Kamber M, Pei J. 2011. *Data Mining: Concepts and Techniques, Ed ke-3*. San Francisco (US): Morgan Kaufmann.
- Jacobsen R. 2012. Digital painting analysis authentication and artistic style from digital reproduction [tesis]. Aalborg (DK): Aalborg University.
- Kairuddin NF, Mahmud MH. 2017. Texture feature analysis for different resolution level of kidney ultrasound images. Di dalam: *IOP Conference Series: Materials Science and Engineering*; Melaka, 2017 Mei 6-7. Bristol(UK): IOP Publishing. hlm 1-9.
- [Kemensekneg] Kementerian Sekretariat Negara. 1999. *Undang-Undang Republik Indonesia Nomor 8 Tahun 1999 tentang Perlindungan Konsumen*. Jakarta (ID): Kemensekneg.
- Kushartono B. 2000. Penentuan kualitas bahan baku pakan dengan cara organoleptik. [Internet]. [diunduh 2016 Mar 6]; [http://balitnak.litbang.pertanian.go.id/index.php?option=com_phocadownload &view=category&id=65:3&download=1011:3&start=20&Itemid=10](http://balitnak.litbang.pertanian.go.id/index.php?option=com_phocadownload&view=category&id=65:3&download=1011:3&start=20&Itemid=10)
- Maulana MR. 2007. Uji pemalsuan dedak padi menggunakan sifat fisik bahan [skripsi]. Bogor (ID): Institut Pertanian Bogor.
- Mahargya 2019. Kontrol Kualitas Dedak Padi Sebagai Bahan Pakan Unggas [Internet]. [Diakses 4 Mei 2022]; <https://disnakkeswan.jatengprov.go.id/index.php/read/kontrol-kualitas-dedak-padi-sebagai-bahan-pakan-unggas>.
- Marcot BG, Hanea AM. 2021. What is an optimal value of k in k-fold cross-validation in discrete Bayesian network analysis? *Comp. Stat* 36(3): 2009-2031.
- Ma'ruf A, Bambang P, Nita A. 2017. Lignin isolation process from rice husk by alkaline hydrogen peroxide: Lignin and silica extracted. *AIP Conference Proceedings*; Bydgoszcz, 2018 Mei 9-11. Now York(US): AIP Publishing.
- Noordama. 2014. Identifikasi varietas durio zibethinus berdasarkan sebaran trikoma daun menggunakan GLCM dan KNN [skripsi]. Bogor (ID): Institut Pertanian Bogor.
- Ridla M, Jayanegara A, Laconi EB, Nahrowi. 2015. *Pengetahuan Bahan Makanan Ternak*. Bogor(ID): IPB Press.
- Rusyidi AM. 2014. Pemalsuan pakan [Internet]. [diunduh 2016 Mar 6]. <http://disnakkeswan.su.lselprov.go.id/files/documents/1423233018-Pemalsuan%20Pakan%20oleh%20Andi%20Muh.%20Rusyidi,%20S.Pt.pdf>
- Sari JP, Erlansari A, Purwandari EP. 2021. Identifikasi citra digital kura-kura Sumatera dengan perbandingan ekstraksi fitur GLCM dan GLRLM berbasis web. *Jurnal Pseudocode* 8(1): 66-75.
- Sidiq F, Wardani WW. 2014. Menghadapi variasi kualitas bahan baku pakan yang beredar di Indonesia [Internet]. [diunduh 2016 Mar 16]; <http://trouwnutrition.co.id/contentassets/4c53cc3eee874ca9b41a97b5e8509c7f/trouw-add-science--aspac---issue-4-indo-final.pdf>
- Singh KSHR. 2016. A comparison of gray-level run-length matrix and gray-level co-occurrence matrix towards cereal grain classification. *Int. J. of Comp. Eng. and Tech* 7(6): 9–17.
- Sjöström E. 1993. *Wood Chemistry, Fundamentals and Applications, Second Edition*. Cambridge(US): Academic Press.
- Sun R. 2020. *Lignin Source and Structural Characterization*. Belgium(BE): European Chemical Societies Publishing.
- Tang X. 1998. Texture information in run-length matrices. *Image Processing*. 7(11): 1602–1609.

- Telaumbanua K, Sudarto, Butar-Butar F, Bilqis PS. 2021. Identifikasi sampah berdasarkan tekstur dengan metode GLCM dan GLRLM menggunakan *improved* KNN. *Explorer* 1(2):45-52.
- Tharwat A. 2020. Classification assessment methods. *Applied Computing and Informatics* 17(1): 168-192.
- Wardani BK, Belinda NE, Rulaningtyas R, Purwanti E. 2020. Application of gray level run-length matrices features extraction for diabetic retinopathy detection based on artificial neural network. *AIP Conf. Proc*; Surabaya, 2019 Okt 22. Now York(US): AIP Publishing.
- Yuliati N. 2016. Estimasi kandungan lignin pada dedak padi yang becampur sekam menggunakan metode knn berbasis tekstur citra [skripsi]. Bogor (ID): Institut Pertanian Bogor.