

Model PNN Untuk Estimasi Kandungan Lignin pada Dedak Padi Bercampur Sekam Berbasis Citra Warna YCbCr

Zuhdi Mukarom Bahri

Program Studi Ilmu Komputer, SSMI, IPB University

Aziz Kustiyo

Program Studi Kecerdasan Buatan, SSMI, IPB University

Firman Ardiansyah

Program Studi Ilmu Komputer, SSMI, IPB University

Muhammad Asyhar Agmalaro

Program Studi Kecerdasan Buatan, SSMI, IPB University

Alamat:

Jl. Raya Dramaga, Kampus IPB Dramaga Bogor, Jawa Barat, Indonesia

Penulis korespondensi: azizku@apps.ipb.ac.id

***Abstract.** Adulteration of rice bran is commonly done by mixing it with materials of similar appearance but lower nutritional value, such as ground rice husk. A key indicator of such adulteration is increased lignin content. Adding phloroglucinol solution to the mixture produces a red color that varies with lignin levels. This study aims to estimate lignin content in rice bran-husk mixtures using artificial intelligence and digital image processing. YCbCr color model images of eleven rice bran-husk compositions, treated with phloroglucinol, were analyzed. The lignin content of each variation was measured in the lab and used to define eleven classes. A Probabilistic Neural Network (PNN) was employed as the classifier, with image histograms of varying bin sizes as input. PNN performance was evaluated using 4-fold cross-validation. Results showed the highest average accuracy of 85.80% with 32 bins and histograms from all three YCbCr channels.*

***Keywords:** histogram, lignin, PNN, rice bran, rice husk.*

LATAR BELAKANG

Pakan adalah segala sesuatu yang dapat dimakan dan dicerna oleh ternak tanpa mengganggu kesehatannya (Nurfritriani & Muhammad, 2021). Pakan merupakan faktor terpenting yang menentukan kualitas serta kuantitas produksi ternak (Novita et al., 2022). Dedak padi adalah produk sampingan dari proses penggilingan padi (Rosani et al., 2024). Dedak padi umum digunakan sebagai pakan ternak di Indonesia, terutama pada peternakan rakyat. Hal ini disebabkan oleh ketersediaan dedak padi yang melimpah dan harganya yang relatif murah (DISKANAK, 2019). Meskipun demikian, tingginya permintaan dan harga yang tidak stabil seringkali memicu praktik pemalsuan. Hal ini terjadi terutama pada musim kemarau (Hernaman et al., 2024).

Received Desember 05, 2025; Revised Desember 24, 2025; Accepted Desember 30, 2025

*Aziz Kustiyo, azizku@apps.ipb.ac.id

Pemalsuan dedak padi umumnya dilakukan dengan mencampurkan bahan lain yang memiliki karakteristik fisik serupa seperti sekam padi yang dihaluskan. Namun demikian, sekam padi tersebut memiliki nutrisi yang lebih rendah (Hernaman et al., 2023). Hasil pengujian di Kabupaten Bogor pada tahun 2019 menunjukkan bahwa sebagian besar sampel dedak padi yang diuji tidak memenuhi Standar Nasional Indonesia (SNI). Temuan ini mengindikasikan adanya pencampuran bahan lain seperti sekam (DISKANAK, 2019). Salah satu indikator utama pemalsuan dedak padi dengan sekam adalah peningkatan kadar lignin. Sekam padi diketahui memiliki kandungan lignin yang signifikan, berkisar antara 25-30% (Hernaman et al., 2024).

Berbagai upaya telah dilakukan untuk mendeteksi pemalsuan dedak padi tersebut, di antaranya metode konvensional seperti uji apung dan pengamatan panca indera. Metode-metode ini, meskipun sederhana, bersifat sangat subjektif dan tidak akurat. Selain itu, terdapat pula metode-metode yang dilakukan di laboratorium seperti metode kromatografi cair (Sabir et al., 2017) dan metode gelombang ultrasonik (Rosani et al., 2024). Namun, metode-metode ini membutuhkan waktu dan biaya yang tinggi sehingga tidak praktis untuk penggunaan di lapangan.

Untuk mengatasi permasalahan tersebut, beberapa penelitian telah dilakukan dengan memanfaatkan metode pengolahan citra digital sebagai alternatif yang lebih praktis dan terjangkau. Salah satu penelitian dilakukan oleh Mutya et al. (2022) menggunakan metode K-Nearest Neighbor (KNN) dan model warna RGB. Penelitian ini mengestimasi kandungan lignin pada campuran dedak padi dan sekam. Hasil penelitian ini mendapatkan akurasi tertinggi mencapai 72.12% dengan mengelompokkan kandungan lignin ke dalam 4 kelas. Penelitian selanjutnya oleh Sutrisno (2023) mengintegrasikan *Principal Component Analysis* (PCA) ke dalam KNN. Penelitian ini didasarkan pada citra warna RGB dan berhasil meningkatkan akurasi KNN menjadi 77.27%. Hasil yang sama juga diperoleh Ajasri (2023) melalui transformasi citra dari RGB ke *grayscale*.

Upaya lebih lanjut dilakukan oleh Parastu et al. (2025) dengan menerapkan metode *Probabilistic Neural Network* (PNN). Penelitian ini memperluas model warna yang digunakan yaitu model warna RGB dan HSV. Di samping itu, penelitian ini membagi target klasifikasi dari 4 kelas menjadi 11 kelas. Meskipun memiliki tugas klasifikasi yang

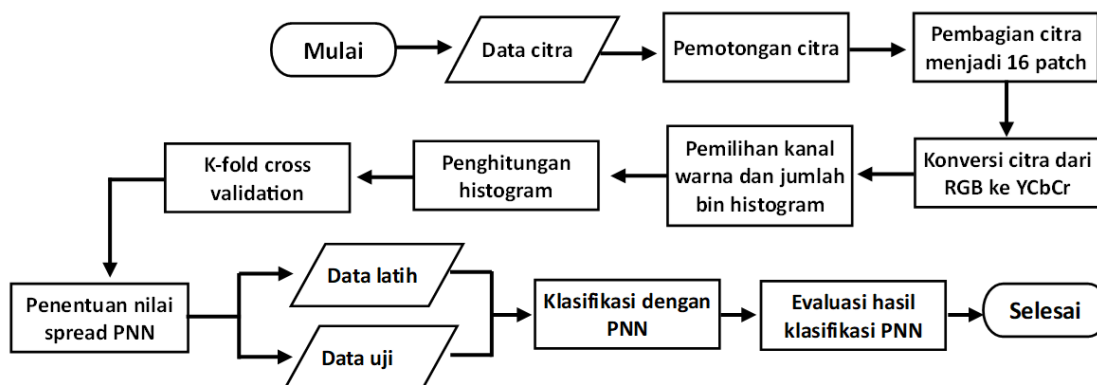
lebih rumit dibandingkan KNN, penelitian ini berhasil meningkatkan akurasi menjadi 79.54%.

Dari rangkaian penelitian tersebut terlihat adanya potensi penelitian lebih lanjut untuk meningkatkan akurasi, di mana akurasi tertinggi saat ini adalah 79.54% (Parastu et al., 2025). Untuk mencapai peningkatan akurasi tersebut, digunakan hasil penelitian dari Boughanem et al. (2023) mengenai *facial expression recognition* (FER). Penelitian tersebut membuktikan bahwa penggantian model warna dari RGB ke YCbCr dapat meningkatkan akurasi secara drastis dari 88.20% menjadi 92.30%.

Berdasarkan uraian di atas, penelitian ini menggabungkan metode PNN yang digunakan oleh Parastu et al. (2025) dan model warna YCbCr yang digunakan oleh Boughanem et al. (2023). Tujuan dari penelitian adalah mengestimasi kandungan lignin pada citra dedak padi yang bercampur sekam menggunakan PNN berdasar citra warna YCbCr dengan peningkatan akurasi klasifikasi yang signifikan. Di samping itu, penelitian ini juga akan membandingkan akurasi PNN menggunakan model warna YCbCr dengan RGB dan HSV.

METODE PENELITIAN

Penelitian ini dilakukan dalam beberapa tahap seperti yang disajikan pada Gambar 1. Secara garis besar, penelitian ini dilakukan dengan membagi citra asal menjadi beberapa patch, kemudian citra-citra tersebut dikonversi dari RGB ke YCbCr. Untuk setiap kombinasi jumlah *bin* histogram dan pilihan kanal YCbCr, dicari nilai *spread* yang menghasilkan akurasi PNN tertinggi. *Spread* merupakan parameter untuk menentukan lebar kernel Gaussian yang menjadi dasar dari PNN (Specht, 1990).



Gambar 1. Tahapan penelitian

1. Citra Dedak Padi

Penelitian ini memanfaatkan dataset citra yang berasal dari studi sebelumnya oleh Mutya et al. (2022). Dataset ini terdiri dari 11 citra dengan resolusi 5184×3456 piksel dengan format JPEG. Setiap citra tersebut merepresentasikan satu kelas dengan kombinasi campuran sekam dan kandungan lignin yang berbeda. Kandungan lignin pada kombinasi campuran dedak dan sekam disajikan pada Tabel 1. Dari Tabel 1 dapat dilihat bahwa semakin tinggi kandungan sekam, semakin tinggi pula kandungan ligninnya.

Tabel 1. Kandungan dedak, sekam, dan lignin pada tiap citra dedak padi

Citra	Dedak (gr)	Sekam (gr)	Lignin (%)
0	10	0	10.19
1	9	1	10.35
2	8	2	10.59
3	7	3	12.31
4	6	4	12.81
5	5	5	13.44
6	4	6	13.50
7	3	7	14.31
8	2	8	16.00
9	1	9	16.07
10	0	10	16.16

Pada penelitian ini, yang dimaksud dengan kelas adalah setiap kombinasi campuran dedak padi dan sekam pada Tabel 1, sehingga terdapat 11 kelas. Estimasi kandungan lignin pada penelitian ini didasarkan kepada kelas-kelas tersebut. Estimasi ini merupakan estimasi kasar yang berarti bahwa estimasi kandungan lignin berada di sekitar nilai lignin pada kelas tersebut. Sebagai contoh, pada Tabel 1, kelas 1 adalah kombinasi dari 10 gram dedak dan 0 gram sekam, dengan nilai lignin 10.19%. Dengan demikian, apabila hasil prediksi PNN dari citra dedak yang diuji adalah kelas 1, maka hal ini berarti kandungan lignin dari dedak tersebut berada di sekitar nilai 10.19%.

2. Pemotongan Citra

Untuk menciptakan dataset yang lebih besar dan seragam dalam proses klasifikasi, setiap citra induk melalui dua tahap pra pemrosesan. Tahap pertama adalah pemotongan (*cropping*), di mana setiap citra awal dipotong menjadi ukuran standar 1200×1200 piksel. Tujuan dari pemotongan ini adalah untuk memfokuskan area analisis

pada bagian yang relevan. Bagian citra yang relevan merupakan bagian citra yang mengandung campuran dedak dan sekam. Di samping itu, pemotongan tersebut akan menghilangkan bagian lain citra yang banyak mengandung elemen lain yang tidak diperlukan.

3. Pembagian Citra Menjadi 16 Patch

Setelah proses *cropping*, setiap citra kemudian dibagi menjadi *grid* 4×4 tanpa tumpang tindih. Proses pembagian ini menghasilkan 16 sampel citra (*patch*) yang lebih kecil dengan ukuran setiap 300×300 piksel. Metode ini diterapkan untuk mengatasi keterbatasan jumlah data yang tersedia, yaitu hanya 11 citra asal, yang tidak mencukupi untuk pelatihan model PNN secara efektif. Dengan membagi setiap citra menjadi beberapa *patch*, jumlah data latih dapat ditingkatkan secara signifikan tanpa perlu memperoleh citra tambahan dari luar. Selain itu, resolusi asli citra yang cukup besar (1200×1200 piksel) dianggap kurang efisien untuk proses pelatihan.

Secara keseluruhan, proses ini menghasilkan total 176 *patch* citra, yang berasal dari 11 kelas dengan setiap kelas menghasilkan 16 *patch*. Dataset inilah yang selanjutnya digunakan untuk tahap penelitian berikutnya.

4. Konversi RGB ke YCbCr

Setiap sampel citra dikonversi dari model warna RGB (*Red*, *Green*, dan *Blue*) ke model warna YCbCr. Model warna YCbCr memisahkan komponen *luminance* (Y) dari komponen *chrominance* (Cb untuk *blue-difference* dan Cr untuk *red-difference*). Konversi dari model warna RGB (dengan asumsi nilai R, G, B dalam rentang 0-255) ke YCbCr dapat dilakukan menggunakan transformasi linier, seperti dinyatakan pada Persamaan 1, 2, dan 3 (Gonzalez & Woods, 2018).

$$Y' = 0,299 * R + 0,587 * G + 0,114 * B \quad (1)$$

$$Cb = -0,168736 * R - 0,331264 * G + 0,5 * B + 128 \quad (2)$$

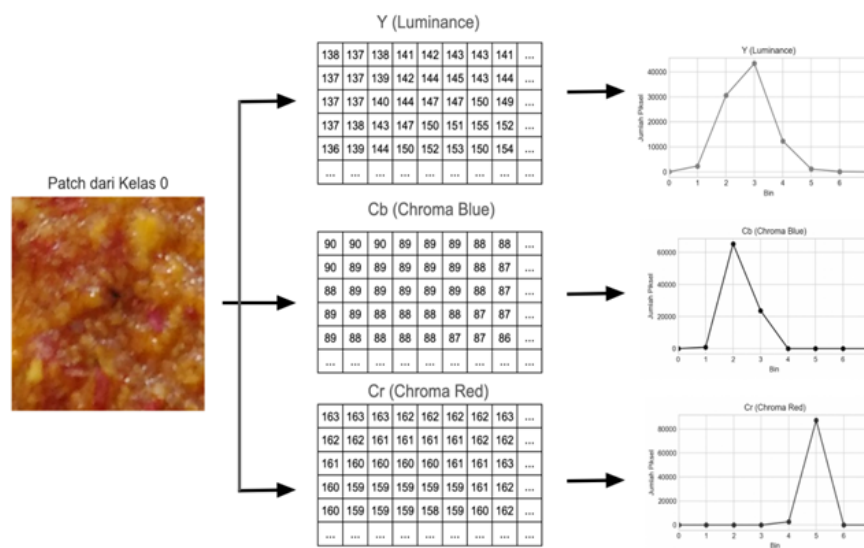
$$Cr = 0,5 * R - 0,418688 * G - 0,081312 * B + 128 \quad (3)$$

5. Menghitung Histogram

Pada Gambar 2, setiap kanal warna YCbCr dengan rentang nilai 0–255 dibagi menjadi 8 *bin* dengan lebar yang sama, sehingga setiap *bin* mencakup 32 tingkat

intensitas. Kemudian, jumlah piksel dalam setiap *bin* dihitung untuk membentuk tabel histogram (Gonzalez & Woods, 2018).

Untuk setiap patch dalam model warna YCbCr, histogram dihitung untuk mengkuantifikasi distribusi intensitas pada setiap kanal. Jumlah *bin* pada histogram divariasikan dengan nilai 8, 16, 32, 64, 128, dan 256 untuk menguji pengaruh tingkat granularitas fitur terhadap akurasi model klasifikasi. Jumlah *bin* yang rendah (contohnya 8 dan 16) lebih tahan terhadap noise dan overfitting namun kurang mencerminkan detail citra. Sebaliknya, jumlah bin yang tinggi (contohnya 128 dan 256) lebih mencerminkan detail citra namun lebih rentan terhadap noise dan overfitting.



Gambar 2. Ilustrasi proses perhitungan histogram dari citra YCbCr

Setelah itu, nilai-nilai dalam setiap vektor histogram dinormalisasi menggunakan metode Z-score (Demircioğlu, 2024). Tujuan dari normalisasi tersebut adalah menghasilkan fitur yang memiliki rerata nol dan standar deviasi satu. Dengan demikian, fitur-fitur yang dihasilkan lebih seragam dan tidak ada fitur yang mendominasi proses klasifikasi karena memiliki rentang nilai numerik yang lebih besar.

Terdapat dua skenario dalam proses ekstraksi fitur histogram. Pada skenario pertama, histogram dihitung secara terpisah untuk setiap kanal Y, Cb, dan Cr. Pada skenario kedua, histogram dihitung dengan menggabungkan dua atau tiga kanal, di mana histogram dari dua atau lebih kanal tersebut disusun menjadi satu vektor fitur tunggal.

6. K-Fold Cross Validation

Metode *k-fold cross validation* (Kohavi, 1995) dipilih untuk mengukur akurasi prediksi PNN dengan lebih akurat. Dataset yang berjumlah 176 *patch* citra, terbagi rata ke dalam 11 kelas dan 16 *patch* per kelas. Kemudian 176 *patch* citra tersebut dipecah menjadi 4 *fold*, masing-masing berisi 44 sampel. Setiap *fold* memiliki satu kesempatan menjadi data uji dari proses pengujian PNN sebanyak 4 kali. Pada setiap pengujian, 3 *fold* menjadi data latih dan 1 *fold* sisanya menjadi data uji.

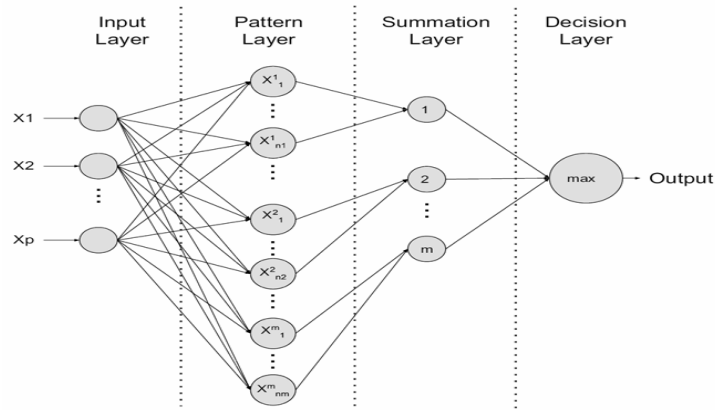
Jumlah 4 *fold* ini dipilih agar jumlah *patch* pada setiap kelas dapat dibagi secara merata, yaitu 4 *patch* per *fold* per kelas. Pembagian secara merata tersebut akan memberikan pembobotan yang sama untuk setiap kelas pada saat proses klasifikasi menggunakan PNN. Dengan demikian akan meningkatkan potensi diperolehnya akurasi klasifikasi PNN yang tinggi.

7. Klasifikasi dengan Probabilistic Neural Network (PNN)

PNN bekerja sebagai jaringan feedforward dengan empat lapisan (Gambar 3), berbasis kernel density estimation (Specht, 1990). Proses klasifikasi meliputi:

- a. *Input layer*, yang berfungsi menerima vektor fitur sampel, yang pada kasus ini berupa nilai-nilai pada histogram *patch* citra yang telah dinormalisasi dengan jumlah *bin* yang telah ditentukan, dan meneruskannya ke lapisan selanjutnya. Sebagai contoh, untuk arsitektur PNN pada Gambar 3 jika jumlah *bin* adalah 8, maka nilai $p=8$.
- b. *Pattern layer*, berisi 12 neuron untuk setiap kelas, yang menunjukkan 12 data latih untuk setiap kelas. Banyaknya kelas adalah 11 sehingga total terdapat 132 neuron pada layer ini (berdasarkan Gambar 3, nilai $n_i=12$ untuk semua i dan nilai $m=11$).
- c. *Summation layer*, terdapat 11 neuron karena terdapat 11 kelas (berdasarkan Gambar 3, nilai $m=11$).
- d. *Decision layer*, berisi 1 neuron, yang merupakan kelas prediksi dari PNN.

Satu-satunya hyperparameter penting di PNN adalah *spread* (σ), yang menentukan lebar kernel Gaussian di *pattern layer*. Untuk memilih *spread* terbaik, dilakukan grid search, dimana untuk setiap konfigurasi fitur (model warna, kombinasi kanal, jumlah *bin*), dicoba nilai *spread* dari 0.1 hingga 5.0 dengan selang 0.1.



Gambar 3. Arsitektur PNN (Mohebbi et al., 2019)


8. Evaluasi Hasil

Untuk setiap nilai *spread*, dihitung rata-rata akurasi dari 4-fold cross-validation. Nilai *spread* dengan akurasi rata-rata tertinggi dipilih sebagai nilai optimal untuk konfigurasi tersebut, misalnya hanya kanal Y dengan 8 *bin*. Proses ini kemudian diulang untuk semua kombinasi parameter hingga seluruh hasil akhir digabung ke dalam satu tabel. Kombinasi parameter dengan akurasi tertinggi akan dianalisis lebih lanjut menggunakan Confusion Matrix.

HASIL DAN PEMBAHASAN


1. Hasil pemotongan citra

Pada Gambar 4a disajikan contoh citra 0 (komposisi 10 gram dedak dan 0 gram sekam). Citra tersebut kemudian dipotong untuk mendapatkan area yang hanya berisi campuran dedak dan sekam saja. Hasil pemotongan citra tersebut disajikan pada Gambar 4b. Selanjutnya citra hasil pemotongan dari citra 0 sampai dengan citra 10 disajikan pada Gambar 5. Dalam konteks klasifikasi dengan PNN maka citra 0 ini merupakan citra kelas 1 dan citra 10 merupakan citra kelas 11.



Gambar 4. Citra kelas 1 (a) Citra asal (b) Citra hasil pemotongan


*ESTIMASI KANDUNGAN LIGNIN PADA DEDAK PADI BERCAMPUR SEKAM
MENGUNAKAN PNN DENGAN MODEL WARNA YCBCR*



Gambar 5. Citra kelas 1 sampai dengan citra kelas 11 hasil pemotongan

2. Hasil Pembagian Citra Menjadi 16 Patch


Citra hasil pemotongan selanjutnya dibagi menjadi grid berukuran 4x4 atau dibagi menjadi 16 citra tanpa tumpang tindih (16 patch). Sebagai ilustrasi, hasil pembagian citra kelas 1 (Gambar 6a) disajikan pada Gambar 6b. Citra inilah yang akan diproses sebagai input untuk klasifikasi PNN.



Gambar 6. (a) Citra kelas 1 (b) Citra hasil pembagian menjadi 16 patch

3. Hasil Konversi RGB ke YCbCr dan Histogram Citra

Selanjutnya 16 patch citra tersebut dikonversi dari model warna RGB ke YCbCr. Sebagai ilustrasi, hasil konversi citra RGB (Gambar 7a) disajikan pada Gambar 7b (kanal Y), Gambar 7c (kanal Cb) dan Gambar 7d (kanal Cr).




Gambar 7. Citra hasil konversi dari RGB ke YCbCr

(a) Citra RGB, (b)Kanal Y, (c) Kanal Cb, (d) Kanal Cr

4. Hasil Perhitungan Histogram Citra

Setelah tahap konversi dari RGB ke YCbCr, tahap berikutnya adalah menghitung histogram untuk setiap kanal. Pada Gambar 8 disajikan contoh hasil perhitungan histogram 8 *bin* untuk kanal Y. Gambar 8b menunjukkan hasil perhitungan histogram dari citra kanal Y (Gambar 8a) sebelum dinormalisasi dengan z-score, sedangkan Gambar 8c menunjukkan histogram hasil normalisasi z-score.



Gambar 8. Hasil perhitungan histogram kanal Y dengan 8 bin
 (a) Citra kanal Y, (b) Histogram asal, (c) Histogram hasil normalisasi

Pada Tabel 2 disajikan contoh hasil perhitungan histogram untuk ketiga kanal sebelum normalisasi dan Tabel 3 nilai-nilai histogram setelah normalisasi z-score. Dari Tabel 2 dapat dilihat bahwa kanal Y memiliki nilai tidak nol yang menyebar dari *bin* ke-1 sampai dengan *bin* ke-8, sedangkan kedua kanal yang lain hanya memiliki nilai tidak nol pada beberapa *bin* tertentu yang berdekatan.

Tabel 2. Contoh histogram dengan 8 bin sebelum dinormalisasi

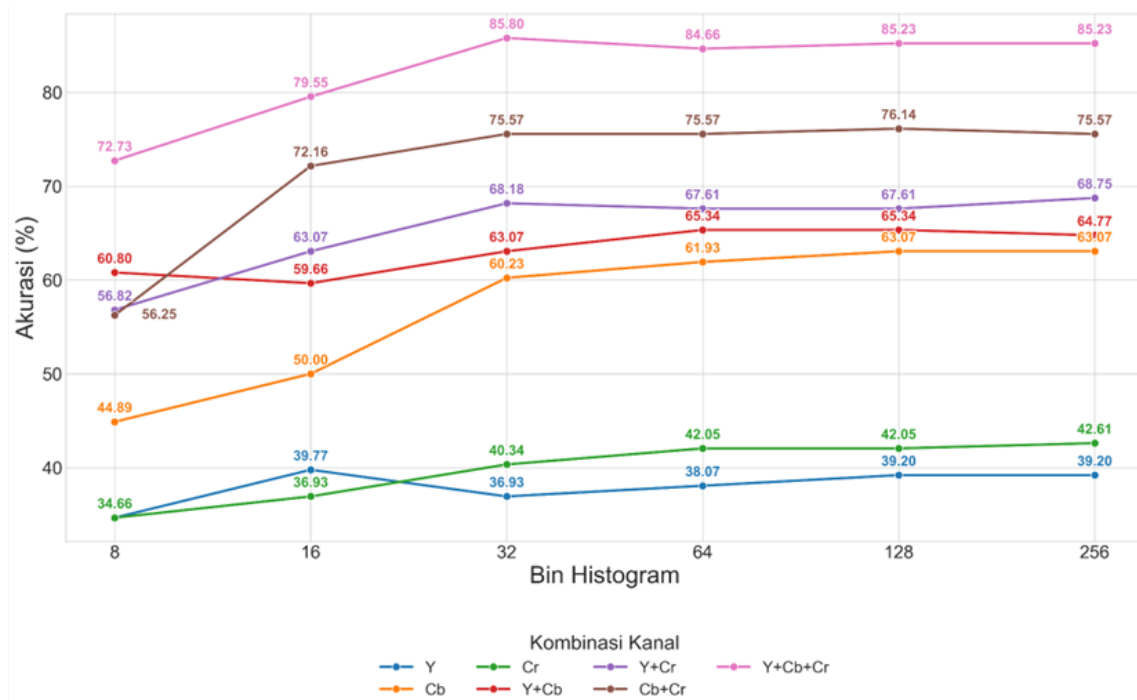
Kanal	Bin							
	1	2	3	4	5	6	7	8
Y	31	2336	30602	43402	12354	1138	132	5
Cb	0	0	0	0	2654	87346	0	0
Cr	0	854	65443	23703	0	0	0	0

Tabel 3. Contoh histogram dengan 8 bin setelah dinormalisasi

Kanal	Bin							
	1	2	3	4	5	6	7	8
Y	-0.7155	-0.5685	1.2341	2.0504	0.0704	-0.6449	-0.709	-0.7171
Cb	-0.391	-0.391	-0.391	-0.391	-0.2987	2.6445	-0.391	-0.391
Cr	-0.514	-0.475	2.4759	0.5689	-0.514	-0.514	-0.514	-0.514

5. Evaluasi Hasil klasifikasi PNN

Akurasi rata-rata PNN pada kombinasi input berupa jumlah *bin* histogram dan jumlah kanal disajikan pada Gambar 9. Untuk setiap kombinasi input tersebut, parameter *spread* PNN yang optimal ditentukan menggunakan 4-fold cross-validation.



Gambar 9. Akurasi rata-rata PNN berdasarkan jumlah *bin* histogram pada setiap kombinasi kanal

Dari Gambar 9 dapat dilihat bahwa secara umum, semakin banyak kanal yang digunakan, maka semakin tinggi akurasi rata-rata PNN yang dihasilkan. Akurasi rata-rata tertinggi PNN untuk penggunaan satu kanal sebesar 63.07% diperoleh dari kanal Cb dengan jumlah *bin* 128. Hal ini menunjukkan bahwa kanal Cb paling banyak mengandung informasi penting untuk mengestimasi kandungan lignin pada campuran dedak padi dan sekam. Untuk kombinasi dua kanal, akurasi rata-rata tertinggi sebesar 76.14% dicapai

oleh gabungan kanal Cb dan Cr pada jumlah *bin* 128. Penggunaan tiga kanal menghasilkan akurasi tertinggi sebesar 85.80% pada jumlah *bin* 32. Hal ini berarti terjadi peningkatan akurasi sebesar 9.66% dibandingkan dengan penggunaan dua kanal. Akurasi tertinggi untuk setiap kombinasi kanal disajikan pada Tabel 4.

Tabel 4. Pengaruh kombinasi kanal YCbCr terhadap akurasi tertinggi

Kombinasi Kanal	Akurasi Tertinggi (%)
Y	39.77
Cb	63.07
Cr	42.61
Y+Cb	65.34
Y+Cr	68.75
Cb+Cr	76.14
Y+Cb+Cr	85.80

Pada Gambar 9 terlihat bahwa secara umum terdapat kecenderungan peningkatan akurasi seiring bertambahnya jumlah *bin*, dengan peningkatan terbesar ditunjukkan pada penggunaan jumlah *bin* dari 8 hingga 32. Sementara itu, peningkatan jumlah *bin* seterusnya hanya menunjukkan perubahan akurasi yang rendah, bahkan dalam beberapa kasus terjadi penurunan akurasi. Pada Tabel 5 disajikan akurasi tertinggi untuk setiap *bin* yang menunjukkan bahwa akurasi tertinggi dicapai pada saat jumlah *bin* 32.

Tabel 5. Perbandingan akurasi tertinggi berdasarkan jumlah *bin*

Jumlah <i>Bin</i>	Akurasi Tertinggi (%)
8	72.73
16	79.55
32	85.80
64	84.66
128	85.23
256	85.23

6. Analisis Hasil Klasifikasi PNN

Pada Tabel 6 disajikan disajikan confusion matrix dari prediksi PNN dengan akurasi tertinggi (85.80%). Berdasarkan confusion matrix tersebut, terlihat bahwa metode klasifikasi yang digunakan mampu menghasilkan akurasi 100% pada kelas 1 (hanya mengandung dedak) dan kelas 11 (hanya mengandung sekam). Kesalahan-kesalahan prediksi pada kelas 2, 3, 4 dan 7 secara umum sama, yaitu salah diprediksi sebagai kelas terdekat, misalnya kelas 2 diprediksi sebagai kelas 3 atau sebaliknya kelas 3 diprediksi sebagai kelas 2, kelas 4 diprediksi sebagai kelas 5 serta kelas 7 diprediksi sebagai kelas

8. Kesalahan-kesalahan tersebut kemungkinan disebabkan oleh adanya persamaan warna karena kedekatan nilai kandungan ligninnya. Untuk kesalahan kelas 4, yang salah diprediksi sebagai kelas 7, 8 dan 9 kemungkinan karena adanya pengaruh faktor lain seperti pencahayaan pada saat pengambilan citra.

Tabel 6 Confusion matrix hasil klasifikasi KNN tertinggi

Kelas Aktual	Kelas Prediksi											
	1	2	3	4	5	6	7	8	9	10	11	
1	16	0	0	0	0	0	0	0	0	0	0	0
2	0	12	4	0	0	0	0	0	0	0	0	0
3	0	4	12	0	0	0	0	0	0	0	0	0
4	0	0	0	9	3	0	1	2	1	0	0	0
5	0	0	0	1	14	0	0	0	1	0	0	0
6	0	0	0	0	0	15	1	0	0	0	0	0
7	0	0	0	1	0	0	12	2	0	1	0	0
8	0	0	0	2	0	0	0	14	0	0	0	0
9	0	0	0	0	0	0	0	0	16	0	0	0
10	0	0	0	0	0	1	0	0	0	15	0	0
11	0	0	0	0	0	0	0	0	0	0	0	16

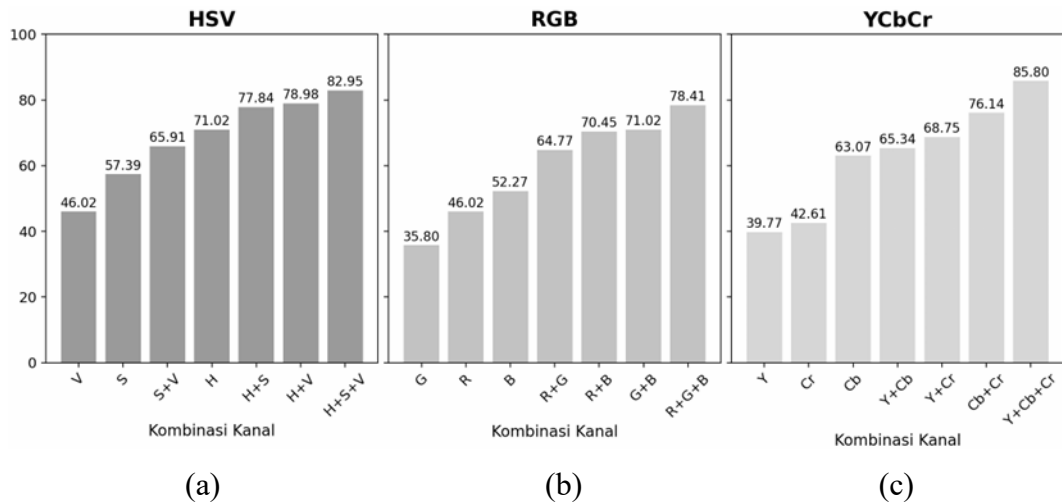
7. Perbandingan Akurasi dengan Model Warna RGB dan HSV

Untuk membandingkan kinerja model warna YCbCr dengan model warna lainnya, tahapan penelitian yang sama juga diterapkan pada ruang warna RGB dan HSV. Perbandingan akurasi tertinggi dari ketiga ruang warna tersebut disajikan pada Gambar 10. Dari Gambar 10 dapat dilihat bahwa akurasi tertinggi dicapai oleh model warna YCbCr (Gambar 10c) dibandingkan dengan RGB (Gambar 10b) dan HSV (Gambar 10a). Hal ini menunjukkan bahwa model warna YCbCr lebih baik dalam memberikan penciri untuk setiap kelas dibandingkan model warna RGB dan HSV. Selain itu, dari Gambar 10 juga dapat dilihat bahwa akurasi tertinggi pada setiap model warna diperoleh dari kombinasi semua kanal.

8. Perbandingan Akurasi dengan Penelitian Sebelumnya

Penelitian ini berhasil mencapai akurasi tertinggi sebesar 85.80%. Akurasi tersebut lebih tinggi dibandingkan akurasi penelitian (Parastu et al., 2025) sebesar 79.54% yang juga menggunakan PNN dengan 11 kelas citra. Akurasi penelitian ini juga lebih tinggi dibandingkan penelitian-penelitian sebelumnya yang menggunakan KNN dan 4 kelas citra. Penelitian-penelitian yang dimaksud adalah penelitian (Mutya et al., 2022)

dengan akurasi sebesar 72.12% serta penelitian (Sutrisno, 2023) dan (Ajasri, 2023) dengan akurasi 77.27%. Hal ini menunjukkan bahwa PNN memiliki kinerja yang lebih baik dalam estimasi kandungan lignin pada campuran dedak padi dan sekam dibandingkan KNN.



Gambar 10. Perbandingan tingkat akurasi maksimal pada setiap kombinasi kanal warna untuk model warna (a) HSV, (b) RGB, (c) YCbCr

KESIMPULAN DAN SARAN

Kombinasi fitur dari model warna YCbCr dengan menggabungkan histogram dari ketiga kanal dan jumlah *bin* sebesar 32 merupakan metode paling efektif untuk mengestimasi kandungan lignin pada dedak padi, dengan akurasi PNN tertinggi sebesar 85,80%. Hasil ini lebih tinggi dibandingkan dengan hasil penelitian-penelitian sebelumnya baik yang menggunakan 11 kelas maupun 4 kelas. Di samping itu, model warna YCbCr juga menghasilkan akurasi PNN yang lebih tinggi dibandingkan akurasi model warna HSV dan RGB.

Untuk pengembangan di masa depan, disarankan untuk menguji robustisitas model pada dataset yang lebih beragam, seperti kondisi pencahayaan yang berbeda, serta dilakukan berbagai augmentasi data citra dengan metode rotasi, perubahan tingkat pencahayaan, dan perubahan ukuran. Kinerja model juga berpotensi ditingkatkan dengan mengintegrasikan fitur tekstur seperti GLCM dan mengeksplorasi algoritma klasifikasi alternatif seperti SVM atau CNN yang dapat menangkap pola yang lebih kompleks. Ke depan, hasil penelitian ini dapat diimplementasikan menjadi sebuah aplikasi praktis

dalam perangkat smartphone yang dapat membantu deteksi kandungan sekam pada dedak padi secara cepat dan objektif di lapangan.

DAFTAR PUSTAKA

- Ajasri, M. (2023). *Estimasi kandungan lignin pada dedak padi menggunakan KNN dengan praproses PCA berdasarkan citra grayscale*. Skripsi. Bogor: Institut Pertanian Bogor.
- Boughanem, H., Ghazouani, H., & Barhoumi, W. (2023). YCbCr color space as an effective solution to the problem of low emotion recognition rate of facial expressions in-the-wild. In *18th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications* (pp. 822–829).
- Demircioğlu, A. (2024). The effect of feature normalization methods in radiomics. *Insights into Imaging*, *15*(2).
- DISKANAK. (2019). *Pembelian dan pencampuran dedak padi sebagai pakan ayam ras dan ayam lokal*. <https://diskanak.bogorkab.go.id/management-pakan-unggas/>. Diakses tanggal 5 April 2025.
- Gonzalez, R. C., & Woods, R. E. (2018). *Digital image processing* (4th ed.). London: Pearson.
- Hernaman, I., Rosani, U., Ayuningsih, B., & Turyana. (2023). Pengujian cepat penentuan cemaran dedak padi dengan sekam padi melalui smartphone di Koperasi Peternak Garut Selatan (KPGS). *Farmers: Journal of Community Services*, *4*(2), 15–19.
- Hernaman, I., Rosani, U., Dhalika, T., Tanuwiria, U. H., Ayuningsih, B., Budiman, A., ... Ismiraj, M. R. (2024). Red-green-blue color analysis concerning rice husk incorporation in rice bran. *Am J Anim Vet Sci.*, *19*(2), 193–199.
- Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. In *the 14th IJCAI* (pp. 1137–1143).
- Mohebbali, B., Tahmassebi, A., Meyer-Baese, A., & Gandomi, A. H. (2019). Probabilistic neural networks: A brief overview of theory, implementation, and application. In *Handbook of Probabilistic Models* (pp. 347–367). Elsevier. <https://doi.org/10.1016/B978-0-12-816514-0.00014-X>
- Mutya, H. M. H., Kustiyo, A., & Jayanegara, A. (2022). Estimasi kandungan lignin pada dedak padi yang bercampur sekam menggunakan KNN berbasis warna citra. In *Prosiding Seminar Nasional MIPA UNIPA* (pp. 95–101).

- Novita, E. D., Kustiyo, A., Jayanegara, A., Haryanto, T., & Adriyanto, H. A. (2022). Prediksi kandungan lignin pada dedak padi bercampur sekam menggunakan tekstur statistik dan KNN. *Jurnal Ilmu Komputer Dan Agri-Informatika*, 9(1), 58–69.
- Nurfitriani, R. A., & Muhammad, N. (2021). *Pengetahuan Bahan Makanan Ternak*. Jakarta: LIPI Press.
- Parastu, R. A., Kustiyo, A., & Agmalaro, M. A. (2025). Estimasi Kandungan Lignin Pada Dedak Padi Bercampur Sekam Menggunakan PNN Berbasis Citra Warna. *Isaintek*, 8(1), 19–32.
- Rosani, U., Hernawan, I., Hidayat, R., & Hidayat, D. (2024). The relationship of lignin and crude fiber in rice bran with ultrasonic wave parameters. *Adv Anim Vet Sci*, 12(4), 791–801.
- Sabir, A., Rafi, M., & Darusman, L. K. (2017). Discrimination of red and white rice bran from Indonesia using HPLC fingerprint analysis combined with chemometrics. *Food Chem*, 221, 1717–1722.
- Specht, D. F. (1990). Probabilistic Neural Networks. *IEEE Transactions on Neural Network*, 1(1), 111–121.
- Sutrisno, R. T. (2023). *Penggunaan KNN Untuk Estimasi Lignin Dalam Dedak Padi Berbasis Citra Warna Dengan Praproses PCA*. Skripsi. Bogor: Institut Pertanian Bogor.