

# Klasifikasi Kualitas Buah Pisang Berdasarkan Citra Buah Menggunakan Stochastic Gradient Descent

Dedy Armiady<sup>1</sup>, Imam Muslem R<sup>2,\*</sup>

<sup>1</sup>Fakultas Ilmu Komputer, Program Studi Informatika Medis, Universitas Almuslim, Bireuen, Indonesia

<sup>2</sup>Fakultas Ilmu Komputer, Program Studi Informatika, Universitas Almuslim, Bireuen, Indonesia

Email: <sup>1</sup>dedy.armiady@gmail.com, <sup>2,\*</sup>imamtkj@gmail.com

Email Penulis Korespondensi: imamtkj@gmail.com

**Abstrak**—Kualitas buah pisang merupakan faktor penting dalam memenuhi permintaan konsumen dan menjaga kualitas produk dalam rantai pasokan. Pengembangan metode otomatis untuk mengklasifikasikan kualitas buah pisang menjadi semakin penting seiring dengan pertumbuhan konsumsi buah pisang di seluruh dunia. Dalam penelitian ini, kami mengajukan metode klasifikasi kualitas buah pisang dengan menggunakan algoritma Stochastic Gradient Descent (SGD). Penelitian ini bertujuan untuk mengevaluasi kinerja SGD dalam mengklasifikasikan kualitas buah pisang dan menganalisis pengaruh pemilihan hyperparameter pada hasil klasifikasi. Dataset yang dikumpulkan berupa dataset yang berisi gambar buah pisang dengan berbagai tingkat kematangan dan kondisi. Dataset ini digunakan untuk melatih dan menguji model klasifikasi menggunakan SGD. Selama eksperimen, dilakukan proses hyperparameter tuning seperti learning rate, momentum, dan ukuran batch untuk memahami bagaimana parameter-parameter ini mempengaruhi kinerja SGD dalam klasifikasi. Kami melaporkan hasil evaluasi klasifikasi berdasarkan akurasi dan menganalisis perubahan performa dengan variasi hyperparameter. Hasil penelitian ini menunjukkan bahwa SGD memiliki potensi dalam mengklasifikasikan kualitas buah pisang, dimana pada model SGD optimal didapatkan akurasi klasifikasi sebesar 99,9%, dibandingkan dengan model SGD standar dimana hanya mendapatkan akurasi klasifikasi sebesar 94,7%.

**Kata Kunci:** Klasifikasi; Buah Pisang; Kualitas; Stochastic Gradient Descent; Hyperparameter.

**Abstract**—Banana fruit quality is an important factor in meeting consumer demand and maintaining product quality in the supply chain. The development of automatic methods for classifying the quality of bananas is becoming increasingly important as the worldwide consumption of bananas grows. In this study, we propose a classification method for banana fruit quality using the Stochastic Gradient Descent (SGD) algorithm. This study aims to evaluate the performance of SGD in classifying the quality of bananas and to analyze the effect of selecting hyperparameters on the classification results. The dataset collected is a dataset containing pictures of bananas with various levels of ripeness and conditions. This dataset is used to train and test a classification model using SGD. During the experiment, hyperparameter tuning processes such as learning rate, momentum, and batch size were carried out to understand how these parameters affect the performance of SGD in classification. We report the results of evaluating the classification based on accuracy and analyze changes in performance with variations in hyperparameters. The results of this study indicate that SGD has the potential to classify the quality of bananas, where the optimal SGD model obtained a classification accuracy of 99.9%, compared to the standard SGD model which only obtained a classification accuracy of 94.7%.

**Keywords:** Classification; Banana Fruit; Quality; Stochastic Gradient Descent; Hyperparameter.

## 1. PENDAHULUAN

Pisang adalah sebuah buah yang berasal dari tumbuhan berjenis *Musa*, keluarga *Musaceae* [1]. Buah ini dikenal dengan bentuknya yang khas, kulitnya yang dapat dikupas, dan rasa manisnya [2]. Pisang adalah salah satu buah yang populer dan dikonsumsi di seluruh dunia. Pisang memiliki kulit berwarna kuning saat matang, tetapi ada juga varietas dengan kulit berwarna hijau, merah, atau bahkan ungu. Daging pisang biasanya berwarna putih atau kuning pucat, tergantung pada jenisnya. Buah pisang mengandung berbagai nutrisi, termasuk karbohidrat seperti glukosa, fruktosa, dan serat diet. Mereka juga mengandung vitamin dan mineral seperti vitamin C, vitamin B6, kalium, dan magnesium. Karena kandungan nutrisinya yang bermanfaat, pisang sering dianggap sebagai camilan sehat dan sumber energi yang baik. Pisang dapat dimakan langsung atau digunakan dalam berbagai hidangan dan makanan, seperti smoothie, roti pisang, kue, es krim, dan banyak lagi. Selain itu, pisang juga memiliki beberapa varietas seperti pisang raja, pisang kepok, pisang ambon, dan lain-lain, yang memiliki ukuran, rasa, dan tekstur yang berbeda-beda [3]–[5].

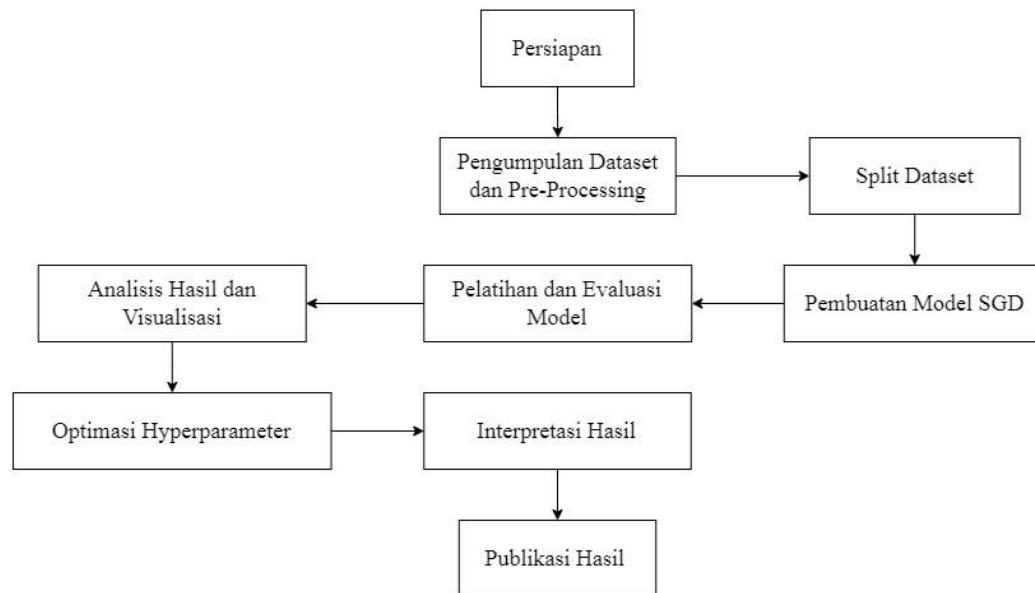
Pisang adalah salah satu buah yang memiliki konsumsi yang sangat tinggi di seluruh dunia. Permintaan yang tinggi terhadap pisang menimbulkan kebutuhan untuk mengembangkan metode yang efektif dalam mengklasifikasikan kualitas buah pisang. Kualitas pisang, yang meliputi tingkat kematangan, keutuhan, dan aspek lainnya, menjadi faktor penting dalam memenuhi ekspektasi konsumen serta menjaga kualitas produk dalam rantai pasokan. Namun, klasifikasi kualitas buah pisang secara manual bisa menjadi pekerjaan yang melelahkan [6], [7], masalah pada efisiensi waktu, serta rentan terhadap ketidakpastian [8]–[16]. Beberapa penelitian telah dilakukan untuk melakukan klasifikasi buah pisang, baik dalam menentukan tingkat kematangan maupun dalam menentukan kualitas serta kematangan buah pisang. Beberapa teknologi berbasis machine learning digunakan dalam melakukan tugas klasifikasi, misalnya seperti klasifikasi buah pisang menggunakan algoritma CNN [3]. Klasifikasi tingkat kematangan buah pisang juga dilakukan oleh [17] dengan menggunakan Naive Bayes. Beberapa penelitian lain juga dilakukan untuk melakukan tugas klasifikasi buah pisang seperti yang dilakukan oleh [18] dengan menggunakan Support Vector Machine, klasifikasi buah pisang berkualitas dengan menggunakan jaringan saraf tiruan [19], bahkan ada juga penelitian yang menggunakan SVM-KNN untuk melakukan klasifikasi jenis pisang berdasarkan warna [5].

Dalam beberapa tahun terakhir, teknologi pengolahan citra dan machine learning telah mengalami perkembangan pesat yang membuka peluang untuk mengotomatisasi proses klasifikasi buah pisang [17]–[23]. Salah satu algoritma optimasi yang umum digunakan dalam pelatihan model machine learning, termasuk untuk tugas klasifikasi, adalah Stochastic Gradient Descent (SGD) [24]. Stochastic Gradient Descent adalah metode optimasi yang mampu menemukan parameter model yang menghasilkan prediksi yang akurat dengan mengiterasi berdasarkan sejumlah sampel data [25]. Namun, meskipun Stochastic Gradient Descent memiliki potensi untuk digunakan dalam klasifikasi kualitas buah pisang, masih perlu diteliti lebih lanjut bagaimana Stochastic Gradient Descent dapat diterapkan dengan efektif untuk tugas ini. Pengaruh pemilihan hyperparameter seperti learning rate, momentum, dan sebagainya pada Stochastic Gradient Descent juga perlu dipahami agar penggunaan Stochastic Gradient Descent dalam klasifikasi buah pisang menghasilkan performa yang optimal [26]. Oleh karena itu, penelitian ini bertujuan untuk menggali potensi penggunaan metode Stochastic Gradient Descent dalam klasifikasi kualitas buah pisang. Dengan melakukan eksperimen yang cermat dan analisis mendalam terhadap parameter Stochastic Gradient Descent, penelitian ini berusaha untuk menyediakan wawasan yang lebih baik tentang efektivitas Stochastic Gradient Descent dalam mengklasifikasikan kualitas buah pisang dan bagaimana mengoptimalkan performa algoritma ini dalam konteks tersebut. Dengan demikian, hasil penelitian ini diharapkan dapat memberikan sumbangan dalam pengembangan solusi otomatis untuk mengklasifikasikan kualitas buah pisang, yang pada akhirnya akan mendukung industri pisang dan memastikan kualitas produk yang lebih baik untuk konsumen.

## 2. METODOLOGI PENELITIAN

### 2.1 Tahapan Penelitian

Adapun alur penelitian yang dilalui dalam penelitian ini dimulai dari proses pengumpulan data hingga publikasi hasil penelitian, dimana rinciannya dapat dilihat pada gambar berikut:



**Gambar 1.** Tahapan Penelitian

Adapun penjelasan dari alur penelitian yang dilakukan adalah sebagai berikut:

- Pengumpulan Data dan Praproses:** Data untuk penelitian ini dikumpulkan dalam bentuk gambar buah pisang dengan berbagai tingkat kematangan dan kondisi. Setiap gambar dianotasi dengan label yang sesuai dengan kualitasnya. Selanjutnya, data gambar tersebut menjalani tahap praproses di mana fitur-fitur ekstraksi diekstraksi dari gambar, termasuk ekstraksi warna, tekstur, dan bentuk. Ini dilakukan untuk mengubah data gambar menjadi bentuk yang dapat dianalisis oleh algoritma klasifikasi.
- Pembagian Data:** Data gambar dibagi menjadi dua bagian utama, yaitu data pelatihan dan data uji. Pembagian ini dilakukan secara acak untuk memastikan representasi yang adil dari setiap kategori kualitas buah pisang dalam kedua subset data tersebut.
- Pembuatan Model dengan SGD:** Dalam tahap ini, model klasifikasi dibuat menggunakan algoritma Stochastic Gradient Descent (SGD) yang diimplementasikan dalam tool Orange Data Mining. Selama pembuatan model, beberapa hyperparameter penting ditentukan, termasuk learning rate yang mengontrol ukuran langkah iterasi, momentum yang mengatur kecepatan konvergensi, dan ukuran batch yang menentukan seberapa banyak sampel yang digunakan dalam setiap iterasi.
- Pelatihan dan Evaluasi Model:** Model yang telah dibuat dilatih dengan menggunakan data pelatihan. Selama pelatihan, model mengiterasi melalui data pelatihan dan mengoptimasi parameter-parameternya berdasarkan hasil perhitungan gradien. Setelah pelatihan selesai, model diuji pada data uji untuk mengukur kinerjanya. Metrik evaluasi yang umum,

- seperti akurasi, presisi, recall, dan F1-score, digunakan untuk mengevaluasi kemampuan model dalam mengklasifikasikan kualitas buah pisang.
- Analisis Hasil dan Visualisasi: Setelah mendapatkan hasil kinerja dari model, langkah selanjutnya adalah menganalisis hasil klasifikasi. Dalam tool Orange Data Mining, analisis ini dapat dilakukan dengan menghasilkan visualisasi seperti confusion matrix untuk melihat di mana model berhasil dan gagal mengklasifikasikan data. Grafik performa berdasarkan variasi hyperparameter juga dapat digunakan untuk melihat pengaruh setiap parameter terhadap kinerja model.
  - Optimasi Hyperparameter: Berdasarkan hasil analisis, langkah optimasi hyperparameter dilakukan. Pemilihan hyperparameter yang optimal dapat mempengaruhi performa model secara signifikan. Dalam tahap ini, berbagai kombinasi hyperparameter dieksplorasi untuk mencari konfigurasi yang paling cocok untuk kasus klasifikasi kualitas buah pisang.
  - Interpretasi Hasil: Setelah mengoptimalkan hyperparameter, hasil akhir dari model klasifikasi dievaluasi dan diinterpretasikan dalam konteks aplikasi. Temuan dari penelitian ini disimpulkan dan dibahas bagaimana penggunaan metode Stochastic Gradient Descent dapat mendukung solusi otomatis dalam mengklasifikasikan kualitas buah pisang, serta implikasinya terhadap industri pisang.
  - Penulisan Laporan: Langkah terakhir adalah menyusun laporan penelitian yang mencakup semua langkah yang telah dilakukan, termasuk latar belakang, tujuan, metodologi, hasil, analisis, kesimpulan, dan rekomendasi untuk penelitian lanjutan. Laporan ini akan mencerminkan keseluruhan proses penelitian serta hasil yang diperoleh.
  - Presentasi Hasil: Hasil penelitian dapat disajikan dalam bentuk presentasi kepada audiens yang relevan, seperti kelompok penelitian, dosen pembimbing, atau komunitas ilmiah. Presentasi ini akan memberikan pemahaman lebih lanjut tentang metode yang digunakan, temuan penelitian, dan implikasinya dalam konteks yang lebih luas.

## 2.2 Dataset

Dataset yang digunakan dalam penelitian ini adalah dataset yang dikumpulkan dari sumber terbuka, yang memuat sebanyak 2200 data citra buah pisang yang terbagi kedalam dua kelas, yaitu Pisang Bagus sebanyak 1113 data dan Pisang Busuk sebanyak 1087 data:



Gambar 1. Dataset

## 3. HASIL DAN PEMBAHASAN

### 3.1 Hasil Penelitian

Stochastic Gradient Descent (SGD) adalah algoritma optimasi yang digunakan secara luas dalam pelatihan model machine learning dan deep learning. Tujuannya adalah untuk menemukan nilai parameter model yang dapat mengurangi nilai fungsi kerugian dengan iterasi melalui dataset pelatihan. Algoritma ini dimulai dengan menginisialisasi parameter model, lalu pada setiap iterasi, secara acak dipilih sejumlah sampel dari dataset pelatihan. Gradien dari fungsi kerugian terhadap parameter dihitung berdasarkan sampel tersebut, dan parameter model diperbarui dengan mengurangi langkah (learning rate) kali gradien. Pendekatan ini menghasilkan stokastisitas dalam perhitungan gradien. Proses ini diulang dalam beberapa iterasi hingga konvergensi tercapai. SGD memiliki variasi seperti Mini-batch SGD, di mana sejumlah kecil sampel dipilih dalam setiap iterasi, serta SGD dengan Momentum, yang menggunakan faktor momentum untuk mempertahankan arah perubahan gradien antar iterasi. Meskipun sederhana, SGD sangat efektif dalam melatih model dalam tugas deep learning dan pemilihan hyperparameter yang tepat sangat penting untuk mencapai konvergensi yang cepat dan stabil [27]–[29].

$$\theta_{t+1} = \theta_t - \alpha \cdot \nabla J(\theta_t; x^{(i)}, y^{(i)}) \quad (1)$$

Model machine learning dalam penelitian ini dirancang menggunakan tool Orange Data Mining, dimana model klasifikasi dibangun menggunakan algoritma jaringan saraf tiruan atau neural network. Adapun Stochastic Gradient Descent digunakan untuk melakukan optimasi proses learning pada jaringan saraf tiruan, dimana SGD akan mengoptimasi

beberapa parameter yang ada dalam jaringan saraf tiruan. Stochastic Gradient Descent (SGD) adalah salah satu teknik optimisasi yang paling umum digunakan dalam machine learning. Tujuan utama dari SGD adalah untuk menemukan nilai parameter model yang optimal dengan meminimalkan fungsi biaya. Dalam konteks SGD, terdapat beberapa parameter yang dapat dikonfigurasi untuk mengoptimalkan proses pembelajaran. Ada beberapa parameter yang digunakan dalam SGD diantaranya adalah:

- a. Learning rate, Learning rate adalah salah satu parameter yang paling penting dalam algoritme Stochastic Gradient Descent (SGD). Parameter ini menentukan seberapa besar langkah yang diambil dalam setiap iterasi ketika menyesuaikan nilai parameter. Learning rate yang terlalu besar dapat membuat algoritme melompati minimum yang diinginkan, sementara learning rate yang terlalu kecil dapat membuat konvergensi menjadi sangat lambat. Sebagai contoh, jika learning rate terlalu besar, SGD mungkin melewati minimum global atau minimum lokal yang diinginkan, sehingga algoritme tidak dapat mencapai konvergensi. Di sisi lain, jika learning rate terlalu kecil, algoritme akan mengambil langkah kecil dalam arah penurunan gradien, yang mungkin membutuhkan jumlah iterasi yang sangat banyak untuk mencapai konvergensi, sehingga proses optimisasi akan berjalan dengan sangat lambat. Oleh karena itu, penting untuk memilih learning rate yang sesuai agar algoritme dapat mencapai konvergensi yang cepat dan stabil. Terkadang, penting juga untuk mengubah learning rate seiring berjalannya waktu.
- b. Epochs, Dalam konteks algoritme Stochastic Gradient Descent (SGD) atau optimisasi pada machine learning, "epoch" merujuk pada satu iterasi lengkap dari seluruh dataset pelatihan. Dengan kata lain, satu epoch berarti model telah melihat dan menjalani pelatihan pada seluruh dataset pelatihan satu kali. Dalam praktiknya, terutama ketika dataset besar, SGD sering kali dijalankan selama beberapa epoch untuk mencapai konvergensi yang optimal. Setiap epoch terdiri dari serangkaian langkah-langkah berikut:
  1. Memecah dataset menjadi batch-batch kecil: Dataset pelatihan seringkali terlalu besar untuk dimuat secara keseluruhan ke dalam memori komputer. Oleh karena itu, dataset biasanya dibagi menjadi batch-batch kecil yang dapat diproses secara terpisah. Setiap batch digunakan untuk menghitung gradien dan memperbarui parameter model.
  2. Melakukan iterasi pada setiap batch: Pada setiap iterasi, SGD menggunakan satu batch data untuk menghitung gradien dari fungsi biaya (loss function) dan memperbarui parameter model. Hal ini dilakukan secara berulang untuk setiap batch hingga seluruh dataset telah dilewati.
  3. Mencatat performa model: Setelah satu epoch selesai, performa model dievaluasi menggunakan dataset validasi atau dataset pengujian untuk mengevaluasi seberapa baik model dapat melakukan prediksi.
- c. Batch Size, Dalam algoritme Stochastic Gradient Descent (SGD) dan berbagai variasinya, "batch size" merujuk pada jumlah sampel data yang digunakan dalam satu iterasi untuk mengestimasi gradien dari fungsi biaya (loss function). Dalam prakteknya, data yang diperoleh sering kali terlalu besar untuk diproses sekaligus, sehingga dataset dibagi menjadi batch-batch yang lebih kecil untuk mengakomodasi keterbatasan memori dan komputasi. Pemilihan batch size memengaruhi beberapa aspek utama dari proses pembelajaran mesin, termasuk:
  1. Kinerja komputasi: Batch size yang terlalu besar mungkin membebani memori dan daya komputasi, terutama jika model yang digunakan sangat kompleks. Sebaliknya, batch size yang terlalu kecil mungkin mempercepat waktu komputasi tetapi juga mengurangi efisiensi penggunaan sumber daya komputasi.
  2. Estimasi gradien: Batch size yang lebih besar dapat memberikan estimasi gradien yang lebih stabil karena mewakili lebih banyak variasi data, tetapi mungkin memperlambat proses optimisasi. Di sisi lain, batch size yang lebih kecil memberikan estimasi gradien yang lebih bervariasi secara stokastik, yang dapat membantu algoritme melompati minimum lokal, tetapi juga dapat memperkenalkan kebisingan ke dalam estimasi gradien.
  3. Keterkaitan antara batch size, learning rate, dan momentum: Pemilihan batch size juga harus dipertimbangkan bersama dengan learning rate dan momentum. Ketika batch size diperbesar, learning rate mungkin perlu disesuaikan untuk mengkompensasi pengaruh peningkatan gradien yang lebih stabil.
- d. Momentum, Dalam konteks algoritme Stochastic Gradient Descent (SGD) dan optimisasi pada machine learning, "momentum" mengacu pada parameter yang digunakan untuk membantu percepatan dan stabilitas konvergensi algoritme optimisasi. Momentum membantu menangani masalah laju konvergensi yang lambat atau kemungkinan terjebak dalam minimum lokal pada fungsi biaya yang kompleks. Konsep momentum dalam SGD dapat dianalogikan dengan konsep fisika. Ketika bola bergulir ke bawah bukit, kecepatan bola bertambah seiring dengan kemiringan lereng. Dalam SGD, momentum bekerja dengan cara yang serupa, yaitu dengan mengakumulasi gradien dari iterasi sebelumnya untuk menyesuaikan langkah-langkah yang diambil dalam arah yang relevan. Dengan adanya momentum, algoritme SGD dapat mengurangi fluktuasi atau "getaran" yang terjadi selama proses optimisasi. Ini membantu algoritme melewati cekungan yang sempit atau minimum lokal yang dangkal dan terus bergerak menuju minimum yang lebih dalam. Momentum dapat ditentukan sebagai parameter tambahan yang biasanya berada dalam rentang 0 hingga 1. Nilai momentum yang lebih tinggi cenderung memberikan dampak yang lebih besar terhadap kecepatan konvergensi, tetapi terlalu tinggi juga dapat menyebabkan algoritme melompati minimum yang diinginkan. Sebaliknya, nilai momentum yang rendah mungkin tidak memberikan dampak yang signifikan terhadap konvergensi.
- e. Decay Rate, parameter ini umumnya digunakan untuk mengoptimalkan laju pembelajaran (learning rate) secara adaptif selama proses optimisasi. Penggunaan decay rate bertujuan untuk mengurangi learning rate seiring dengan berjalannya waktu atau jumlah iterasi, dengan harapan bahwa langkah yang lebih kecil akan membantu SGD mendekati minimum global atau minimum lokal dengan lebih efisien. Dengan penurunan learning rate yang lambat

seiring waktu, algoritme dapat menyesuaikan diri terhadap lingkungan optimisasi yang berubah seiring dengan kemajuan iterasi. Beberapa metode umum yang memanfaatkan konsep decay rate antara lain:

1. Learning rate scheduling: Mengurangi learning rate secara sistematis berdasarkan jadwal tertentu, seperti secara linier atau eksponensial seiring dengan berjalannya waktu atau jumlah iterasi.
  2. Learning rate decay: Mengurangi learning rate secara eksponensial dengan faktor penurunan (decay factor) tertentu setelah setiap epoch atau sejumlah iterasi tertentu.
  3. Adaptive learning rate methods: Metode optimisasi adaptif seperti AdaGrad, RMSprop, dan Adam, yang secara dinamis menyesuaikan learning rate berdasarkan perubahan parameter selama proses optimisasi
- f. Loss Function, Loss function pada SGD (Stochastic Gradient Descent) adalah fungsi yang mengukur seberapa buruk atau bagus performa model dalam memprediksi output yang benar dari input yang diberikan. Loss function biasanya digunakan sebagai acuan untuk menghitung gradien yang akan digunakan oleh algoritme optimisasi, seperti SGD, untuk menyesuaikan parameter model dalam upaya meminimalkan kesalahan prediksi. Salah satu contoh dari loss function yang umum digunakan adalah Mean Squared Error (MSE) untuk masalah regresi. Rumus lengkap dari MSE adalah sebagai berikut:

$$L(y, \hat{y}) = -\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2)$$

di mana:

1. L adalah fungsi kerugian (loss function).
2. y adalah nilai target yang sebenarnya.
3.  $\hat{y}$  adalah nilai prediksi yang dihasilkan oleh model.
4. n adalah jumlah sampel data.

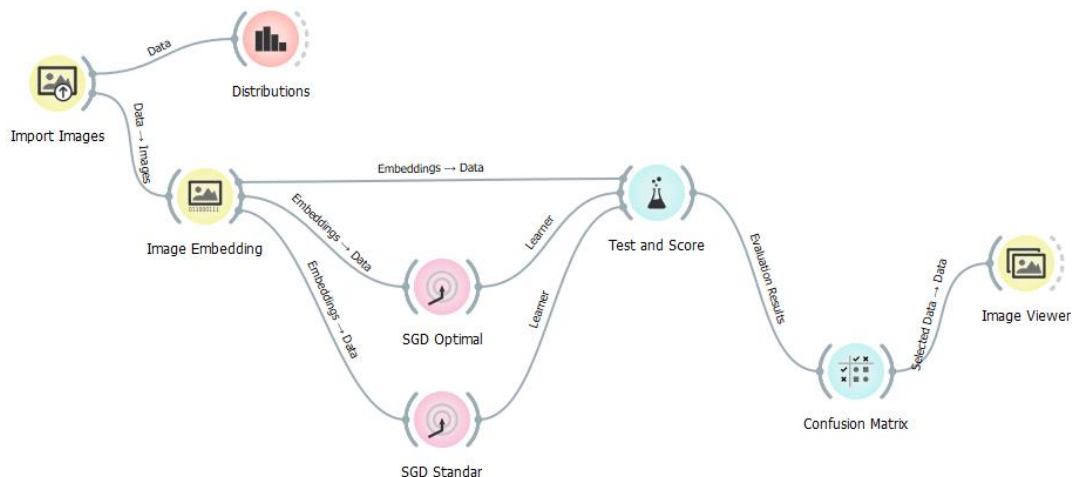
Selain itu, untuk masalah klasifikasi, salah satu contoh dari loss function yang umum digunakan adalah Cross-Entropy Loss. Jika  $y$  adalah label yang benar dan  $\hat{y}$  adalah probabilitas prediksi yang diberikan oleh model, maka rumus Cross-Entropy Loss adalah sebagai berikut:

$$L(y, \hat{y}) = -\frac{1}{n} \sum_{i=1}^n y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i) \quad (3)$$

di mana:

1. L adalah fungsi kerugian (loss function).
2. y adalah label yang benar dalam bentuk one-hot encoding.
3.  $\hat{y}$  adalah probabilitas prediksi yang diberikan oleh model.
4. n adalah jumlah sampel data.

Adapun rancangan model klasifikasi kualitas buah pisang dapat dilihat pada gambar berikut:



**Gambar 3.** Rancangan Model Klasifikasi Buah Pisang

Dalam penelitian ini model dirancang menggunakan tool Orange Data Mining, dimana pada proses awal digunakan widget Import Image untuk mengimport seluruh dataset citra buah pisang. Dalam proses ini dataset yang di import berupa data citra gambar sebanyak 2200 gambar, yang terbagi menjadi dua kelas, yaitu Pisang Bagus sebanyak 1113 data dan Pisang Busuk sebanyak 1087 data. Proses berikutnya yaitu menggunakan widget Image Embedding untuk melakukan konversi data menjadi data numerikal, dimana pada proses ini digunakan SqueezeNet sebagai embedderynya. SqueezeNet adalah salah satu arsitektur model Convolutional Neural Network (CNN) yang dirancang untuk mencapai keseimbangan antara akurasi dan ukuran model. Arsitektur ini dikenal karena kemampuannya menghasilkan model yang lebih ringan tanpa mengorbankan performa yang signifikan. SqueezeNet dikembangkan dengan fokus pada mengurangi jumlah parameter dalam model, yang pada gilirannya mengurangi kompleksitas dan ukuran model. Hal ini sangat penting dalam implementasi model pada perangkat dengan sumber daya terbatas, seperti perangkat mobile atau Internet of Things (IoT) yang memiliki batasan komputasi dan memori.

Proses berikutnya adalah menambahkan dua model Stochastic Gradient Descent (SGD), dengan rincian parameter sebagai berikut:

**Tabel 1.** Parameter Model SGD

Parameter	Model	
	SGD Standar	SGD Optimal
Classification	Hinge	Hinge
Regression	Squared Loss	Squared Loss
Regularization	Ridge (L2)	Ridge (L2)
$\alpha$	0,00001	0,00001
Learning Rate	Invers Scaling	Constant
$\eta$	1	0,0001
t	1	0,2500
Number of Iteration	1000	1000
Tolerance	0,0010	0,0010
FR for Random Shuffling	5	0

Setelah proses hyperparameter tuning dilakukan, yaitu dengan membandingkan dua model SGD dengan parameter yang berbeda, maka proses selanjutnya yaitu menggunakan widget Test and Score untuk mengevaluasi model yang dibangun. Proses test and score dilakukan menggunakan Random Sampling, dimana digunakan sebesar 20% data training sebagai data uji. Adapun hasil yang didapatkan pada pengujian test and score untuk kedua model tersebut dapat dilihat pada gambar berikut:

Model	Train	AUC	CA	F1	Prec	Recall	MCC	LogLoss
SGD Optimal	11.876	0.999	0.999	0.999	0.999	0.999	0.999	0.024
SGD Standar	20.167	0.942	0.942	0.942	0.943	0.942	0.885	2.017

**Gambar 4.** Hasil Test and Score

**3.2 Pembahasan**

Berdasarkan hasil test and score dari kedua model SGD yang telah disebutkan pada bagian sebelumnya, maka didapatkan hasil bahwa model SGD optimal lebih baik daripada model SGD standar. Model SGD optimal yang menggunakan hyperparameter tuning mendapatkan nilai akurasi klasifikasi sebesar 99,9%, dengan waktu training sebesar 11,876 dan loss sebesar 0,024. Hal ini berbeda dengan model SGD standar, dimana akurasi klasifikasi yang didapatkan adalah sebesar 94,2%, waktu training 20,167 serta loss sebesar 2,017.

Dari perhitungan test and score yang dijalankan, maka langkah berikutnya yaitu menguji hasil klasifikasi dengan menggunakan confusion matrix. Confusion matrix adalah tabel evaluasi yang digunakan dalam klasifikasi supervised learning untuk membandingkan hasil prediksi model dengan label kelas sebenarnya pada dataset uji. Ini terdiri dari empat komponen utama: True Positives (data yang benar-benar diklasifikasikan dengan benar sebagai positif), True Negatives (data yang benar-benar diklasifikasikan dengan benar sebagai negatif), False Positives (data yang salah diklasifikasikan sebagai positif), dan False Negatives (data yang salah diklasifikasikan sebagai negatif). Dari komponen ini, metrik evaluasi seperti akurasi, presisi, recall, dan F1-score dapat dihitung, memberikan pemahaman yang lebih mendalam tentang kinerja model dan jenis kesalahan yang dilakukannya. Adapun hasil perhitungan confusion matrix untuk tiap model dapat dilihat pada gambar berikut ini:

		Predicted		$\Sigma$
		Pisang Bagus	Pisang Busuk	
Actual	Pisang Bagus	2042	188	2230
	Pisang Busuk	69	2101	2170
$\Sigma$		2111	2289	4400

**Gambar 5.** Confusion Matrix Model SDG Standar

Pada model SGD standar, dapat dilihat bahwa terjadi kesalahan klasifikasi dimana terdapat 188 data pisang bagus yang diprediksi sebagai pisang busuk. Disamping itu, terdapat 69 data pisang busuk yang diprediksi sebagai pisang bagus. Adapun data hasil kesalahan prediksi tersebut dapat dilihat pada gambar berikut:



**Gambar 6.** Kesalahan Klasifikasi Model SGD Standar

Adapun pada model SGD optimal yang dilakukan hyperparameter tuning dengan akurasi 99,9%, kesalahan klasifikasi dapat dilihat pada confusion matrix sebagai berikut:

		Predicted		$\Sigma$
		Pisang Bagus	Pisang Busuk	
Actual	Pisang Bagus	2228	2	2230
	Pisang Busuk	1	2169	2170
$\Sigma$		2229	2171	4400

**Gambar 7.** Confusion Matrix Model SGD Optimal

Pada confusion matrix model SGD optimal, dapat dilihat bahwa hanya terdapat 2 data kesalahan klasifikasi, dimana kelas sebenarnya adalah pisang bagus, diprediksi sebagai pisang busuk. Pada actual pisang busuk, juga terdapat 1 data yang diprediksi sebagai pisang bagus. Adapun hasil kesalahan klasifikasi model SGD optimal dapat dilihat pada gambar berikut:



**Gambar 8.** Kesalahan Klasifikasi Model SGD Optimal

## 4. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan, serta pembahasan pada bagian sebelumnya, penulis dapat menarik beberapa kesimpulan diantaranya adalah parameter learning rate berpengaruh pada akurasi klasifikasi dari model machine learning. Adapun penggunaan Stochastic Gradient Descent (SGD) berdampak pada optimalnya proses pembelajaran pada machine learning dalam mengklasifikasikan citra buah pisang berdasarkan kualitasnya. Dari pengujian yang dilakukan pada penelitian ini, model SGD optimal dengan learning rate 0,0001 mendapatkan hasil yang baik, dimana akurasi klasifikasi yang didapatkan sebesar 99,9 %. Hal ini berbeda dengan model SGD Standar yang menggunakan learning rate sebesar 1,000 dimana didapatkan hasil akurasi klasifikasi sebesar 94,2%. Model SGD Optimal memiliki waktu proses yang lebih cepat dibandingkan dengan model SGD standar, hal ini dikarenakan parameter SGD yang diatur mampu mencapai konvergensi yang lebih baik dibandingkan dengan model SGD standar.

## REFERENCES

- [1] E. Riandini, R. R. S. Astuti, and M. R. Setiawan, "Jenis-Jenis Pisang (Musaceae) di Kecamatan Curup Tengah Kabupaten Rejang Lebong Types of Banana (Musaceae) in Curup Tengah District, Rejang Lebong Regency," *Biologica Samudra*, vol. 3, no. 1, 2021.
- [2] F. K. Arinta, F. S. Pranata, and Y. R. Swasti, "Potensi daging buah pisang dan kulit pisang (Musaceae) untuk peningkatan kualitas roti dan kue," *Teknologi Pangan : Media Informasi dan Komunikasi Ilmiah Teknologi Pertanian*, vol. 12, no. 2, 2021, doi: 10.35891/tp.v12i2.2416.
- [3] G. Gampur, I. W. Ordiyasa, and S. Hasta Mulyani, "Klasifikasi Jenis Pisang Menggunakan Convolutional Neural Network," *Seminar Nasional Teknik Elektro, Informatika dan Sistem Informasi*, vol. 1, no. 1, 2022, doi: 10.35842/sintaks.v1i1.6.
- [4] K. H. Wardhany, *Khasiat Ajaib Pisang Khasiatnya A to Z Dari Akar Hingga Kulit Buahnya*. 2014.
- [5] Y. E. Yana and N. Nafi'iyah, "Klasifikasi Jenis Pisang Berdasarkan Fitur Warna, Tekstur, Bentuk Citra Menggunakan SVM dan KNN," *RESEARCH : Journal of Computer, Information System & Technology Management*, vol. 4, no. 1, 2021, doi: 10.25273/research.v4i1.6687.
- [6] I. Muslem, "Prototype Kunci RFID (Radio Frequency Identification) dalam Meningkatkan Keamanan Kendaraan Bermotor," *JURNAL TIKA*, vol. 5, no. 3, 2021, doi: 10.51179/tika.v5i3.104.
- [7] T. Firmansyah and I. M. R., "Visualisasi Instruksi Kerja Sistem Informasi Pelelangan Online E-Auction Pt Pupuk Iskandar Muda Berbasis Multimedia," *Tika*, vol. 4, no. 1, 2019.
- [8] V. Aurelly, "Kinetika Perubahan Kualitas Pisang Kepok Tanjung (Musa Paradisiaca L.) Pada Pemeraman Menggunakan Ethepon Di Bawah Pengaruh Suhu Penyimpanan," *pisang kepok*, 2022.
- [9] G. E. Gunawan, "Kualitas nugget berbahan dasar jantung pisang," *Jurnal Ilmiah Pariwisata dan Bisnis*, vol. 1, no. 8, 2022, doi: 10.22334/paris.v1i8.133.
- [10] I. Muslem R., "Sistem Pendeteksi Kebocoran Gas Rumah Tangga Menggunakan Mq-2 Sensor Dan Mikrokontroler," *JURNAL TIKA*, vol. 6, no. 02, 2021, doi: 10.51179/tika.v6i02.457.
- [11] D. Armiaedy and I. Muslem R., "Penetapan Klaster Siswa Unggul Dengan Menggunakan Algoritma Roc-Smarter," *Jurnal TIKA*, vol. 7, no. 2, 2022, doi: 10.51179/tika.v7i2.1229.
- [12] F. Fitriani and I. Muslem R., "E-Absensi Mahasiswa Fakultas Ilmu Komputer Universitas Almuslim Berbasis Web," *JURNAL TIKA*, vol. 5, no. 3, 2021, doi: 10.51179/tika.v5i3.141.
- [13] S. Winar, E. Rizki Putra, and I. Muslem R., "Sistem Informasi Kalkulasi Zakat Pada Kantor Baitul Mal Kabupaten Bireuen Berbasis Android," *Jurnal TIKA*, vol. 7, no. 3, 2022, doi: 10.51179/tika.v7i3.1584.
- [14] T. Fakhurrazzi, T. M. Johan, and I. Muslem R., "Rancang Bangun Sistem Pengamanan Pintu Rumah Menggunakan Android Berbasis Arduino Uno," *Jurnal Ilmu Komputer Aceh*, vol. 1, no. 1, 2023, doi: 10.51179/ilka.v1i1.1896.
- [15] R. Dewi, T. M. Johan, and I. Muslem R., "Aplikasi Kriptografi Dalam Mengamankan Pesan Teks Dengan Metode Algoritma Rc4 Berbasis Android," *JURNAL TIKA*, vol. 6, no. 01, 2021, doi: 10.51179/tika.v6i01.416.
- [16] I. R. Muslem and T. M. Johan, "KLIK: Kajian Ilmiah Informatika dan Komputer Klasifikasi Citra Ikan Menggunakan Algoritma Convolutional Neural Network dengan Arsitektur VGG-16," *Media Online*, vol. 4, no. 2, pp. 978–985, 2023, doi: 10.30865/klik.v4i2.1209.
- [17] Z. Hakim, S. Rahayu, and K. Irawati, "Klasifikasi Tingkat Kematangan Buah Pisang Kepok Menggunakan Algoritma Naive Bayes," *Academic Journal of Computer Science Research*, vol. 4, no. 1, 2022, doi: 10.38101/ajcsr.v4i1.442.
- [18] Y. Amrozi, D. Yuliaty, A. Susilo, N. Novianto, and R. Ramadhan, "Klasifikasi Jenis Buah Pisang Berdasarkan Citra Warna dengan Metode SVM," *Jurnal Sisfokom (Sistem Informasi dan Komputer)*, vol. 11, no. 3, 2022, doi: 10.32736/sisfokom.v11i3.1502.
- [19] A. Harjoko and U. G. Mada, "Pemrosesan Citra Digital untuk Klasifikasi Mutu Buah Pisang Menggunakan Jaringan Saraf Tiruan," *IJEIS (Indonesian Journal of Electronics and Instrumentation Systems)*, vol. 4, no. 1, 2014, doi: 10.22146/ijeis.4222.
- [20] S. P. Adenugraha, V. Arinal, and D. I. Mulyana, "Klasifikasi Kematangan Buah Pisang Ambon Menggunakan Metode KNN dan PCA Berdasarkan Citra RGB dan HSV," *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 6, no. 1, 2022, doi: 10.30865/mib.v6i1.3287.
- [21] M. F. Ajizi, D. Syaupy, and M. H. H. Ichsan, "Klasifikasi Kematangan Buah Pisang Berbasis Sensor Warna Dan Sensor Load Cell Menggunakan Metode Naive Bayes," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 2019.
- [22] J. Jusrawati, A. Futri, and A. B. Kaswar, "Klasifikasi Tingkat Kematangan Buah Pisang Dalam Ruang Warna RGB Menggunakan Jaringan Syaraf Tiruan (JST)," *Journal of Embedded Systems, Security and Intelligent Systems*, vol. 2, no. 1, 2021, doi: 10.26858/jessi.v2i1.20327.
- [23] A. D. Putro and A. Hermawan, "Pengaruh Cahaya dan Kualitas Citra dalam Klasifikasi Kematangan Pisang Cavendish Berdasarkan Ciri Warna Menggunakan Artificial Neural Network," *MATRIK : Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, vol. 21, no. 1, 2021, doi: 10.30812/matrik.v21i1.1396.

- [24] K. Marti, *Stochastic optimization methods: Applications in engineering and operations research*. 2015. doi: 10.1007/978-3-662-46214-0.
- [25] V. Gandikota, D. Kane, R. K. Maity, and A. Mazumdar, "VqSGD: Vector Quantized Stochastic Gradient Descent," *IEEE Trans Inf Theory*, vol. 68, no. 7, 2022, doi: 10.1109/TIT.2022.3161620.
- [26] J. Sirignano and K. Spiliopoulos, "Stochastic gradient descent in continuous time: A central limit theorem," *Stochastic Systems*, vol. 10, no. 2, 2020, doi: 10.1287/stsy.2019.0050.
- [27] J. An, J. Lu, and L. Ying, "Stochastic modified equations for the asynchronous stochastic gradient descent," *Information and Inference*, vol. 9, no. 4, 2020, doi: 10.1093/IMAIA/IAZ030.
- [28] K. Marti, *Stochastic optimization methods (Second edition)*. 2008. doi: 10.1007/978-3-540-79458-5.
- [29] W. Li, Z. Wu, T. Chen, L. Li, and Q. Ling, "Communication-Censored Distributed Stochastic Gradient Descent," *IEEE Trans Neural Netw Learn Syst*, vol. 33, no. 11, 2022, doi: 10.1109/TNNLS.2021.3083655.