

BAB II

TINJAUAN PUSTAKA

Dalam bab tinjauan pustaka ini berisikan penjelasan referensi terbaru dan terdahulu, dengan konsep dan teori dasar yang terkait, untuk pembuatan laporan tugas akhir skripsi, yang berkaitan dengan judul yang di gunakan dalam penelitian “Klasifikasi jenis buah berdasarkan fitur warna, tekstur dan bentuk dari citra dengan metode *k-nearest neighbor*”.

2.1 Penelitian Terdahulu

Tinjauan pustaka merupakan bagian yang akan membahas penelitian terdahulu tentang penyelesaian masalah yang akan memberikan jalan keluar. Dalam hal ini akan membahas beberapa jurnal yang terkait dengan masalah yang akan diangkat.

Pada penelitian yang dilakukan (Indrawati, 2017) adalah melakukan Klasifikasi kematangan jeruk Jeruk dengan menggunakan metode KNN, dan menggunakan fitur RGB dengan hasil akurasi mencapai antara 81% sampai 88.89%. Penelitian yang dilakukan (Ichwan, Dewi, & Muharom, 2018) tentang Klasifikasi Support Vector Machine (SVM) Untuk Menentukan Tingkat Kemanisan buah Mangga menggunakan Fitur Warna. Hasil dari alat pengukur tingkat kemanisan mempunyai nilai akurasi sebesar 83%. Dan hasil dari KNN dengan $k=7$ adalah data valid 21 dan data tidak valid 3 dari 24 data.

Klasifikasi mutu buah jambu biji menggunakan metode KNN berdasarkan fitur warna dan tekstur yang dilakukan oleh (Prahudaya & Harjoko, 2017) KNN dirancang dengan memasukkan 7 fitur ekstraksi yaitu nilai rata-rata RGB (Red, Green, Blue), Nilai GLCM (energy, homogeneity dan contrast), dan luas cacat. Dari hasil pengujian yang didapatkan bahwa metode klasifikasi ini mampu memberikan nilai akurasi terbaik pada K3 yaitu dengan nilai akurasi sebesar 91,25%.

Proses identifikasi dan prediksi tingkat kematangan buah pisang candi dapat menggunakan fitur warna dan fitur tekstur dengan KNN (Rahmad, Astiningrum, Purnomo, & budi, 2019) dengan mengkonversikan algoritma RGB ke *Hue Saturation Intensity* sebagai fitur warna sedangkan algoritma GLCM sebagai fitur

tekstur dan hasil akurasi sebesar 90%. Penelitian yang dilakukan (Ratnasari, Kamilah, & Anggit, 2016) pengenalan jenis buah pada citra menggunakan klasifikasi dengan menggunakan metode KNN, hasil akurasi tertinggi sebesar 92%.

Dalam penelitian (Khotimah, Nafi'iyah, & Masruroh, 2019). Dengan dataset 129 data training serta 40 data testing di mana citra RGB dikonversi menjadi ke bentuk HSV, pada proses klasifikasi kematangan dibagi menjadi 4 kelas, yaitu: mentah, cukup matang, matang dan sangat matang, dengan menggunakan metode KNN hasil akurasi tertinggi pada $k=2$ sebesar 80%. Penelitian yang dilakukan oleh (Irwan Siswanto & Raharjo, 2020) tentang klasifikasi tingkat kematangan buah berdasarkan fitur warna dan tekstur dengan metode KNN dan *Nearest mean Classifier*. Untuk metode KNN melakukan klasifikasi tingkat kematangan menggunakan fitur warna dan kombinasi fitur tekstur dan menghasilkan nilai akurasi kebenaran sebesar 73% sedangkan metode *Nearest mean Classifier* menghasilkan nilai akurasi sebesar 70%.

Tabel 2.1 merupakan *state of the art* dari beberapa penelitian terkait tentang klasifikasi buah.

Tabel 2. 1 State of The Art

No	Judul	Penulis	Tahun	Metode	Hasil
1.	Klasifikasi Buah Belimbing Berdasarkan Citra Red-Green-Blue Menggunakan Knn Dan Lda	Retno Nugroho Whidhiasih , Nursinta Adi Wahanani , Supriyanto	2013	K-Nearest Neighbor (KNN) Dan Linier Discriminant Analysis (LDA)	Metode KNN menghasilkan akurasi 80%, hasil variabel RGB mencapai 91%. dan hasil teknik LDA mencapai 91%.
2.	Klasifikasi Tingkat Kematangan Buah Apel Manalagi Dengan Algoritma Naive Bayes Dan Ekstraksi Fitur Citra Digital	Antonio Ciputra, De Rosal Ignatius Moses Setiadi, Eko Hari Rachmawanto, Ajib Susanto	2018	Naive Bayes, Dan Ekstraksi Fitur (Fitur Rerata Intensitas, Fitur Energi, Fitur Entropi, Fitur Standar Deviasi, Fitur Skweness, Fitur Smothness)	Hasil akurasi metode ini sebanyak 63%.

Tabel 2.1 State Of The Art (Lanjutan)

3.	Klasifikasi Jenis Buah Apel Dengan Metode K-Nearest Neighbors	Novan Wijaya, Anugrah Ridwan	2019	K-Nearest Neighbors (KNN)	Hasil secara keseluruhan bahwa nilai rata-rata <i>precision</i> sebesar 94%, nilai <i>Recall</i> 100%, dan nilai <i>Accuracy</i> 94%.
4.	Klasifikasi Kematangan Jeruk Lemon Menggunakan Metode K-Nearest Neighbour	Indrawati	2017	K-Nearest Neighbors (KNN)	Hasil akurasi antara 81% sampai 88,89%
5.	Klasifikasi Kematangan Buah Mangga Berdasarkan Citra HSV dengan KNN	Husnul Khotimah, Nur Nafi'iyah, Masruroh	2019	K-Nearest Neighbours (KNN)	Hasil akurasi tertinggi pada k=2 adalah 80%. Dan alat untuk pengembangan sistem adalah matlab.
6.	Klasifikasi Support Vector Machine (SVM) Untuk Menentukan Tingkat Kemanisan Mangga Berdasarkan Fitur Warna	Muhammad Ichwan, Irma Amelia Dewi, Zeni Muharom S	2018	Support Vector Machine (SVM) dan K-Nearest Neighbour (K-NN)	Hasil dari alat pengukur tingkat kemanisan mempunyai nilai akurasi sebesar 83%. Dan hasil dari KNN dengan k=7 adalah data valid 21 dan data tidak valid 3 dari 24 data.
7.	Klasifikasi Kematangan Buah Jeruk Berdasarkan Fitur Warna Menggunakan Metode SVM	Muchammad Arief	2019	metode svm (Support Vector Machine)	Hasil akurasi kecocokan mencapai 80% dari 100 citra.

Tabel 2.1 State Of The Art (Lanjutan)

8.	Klasifikasi Kematangan Stroberi Berbasis Segmentasi Warna dengan Metode HSV	Indrabayu, Nurhikma Arifin , Intan Sari Areni	2019	metode yang digunakan adalah Hue, Saturation, Value (HSV) dan klasifikasi menggunakan algoritma Multi-Class Support Vector Machine (SVM)	Hasil klasifikasi menggunakan SVM menghasilkan akurasi tinggi sebanyak 97%.
9.	Identifikasi Kualitas Strawberry Berdasarkan Warna Dan Tekstur Dengan Menggunakan Gray Level Co-occurrence Dan Naïve Bayes	Cahya Rahmad, Agung Nugroho Pramudhita , Akhmadhon Sofiyanto	2020	Naïve Bayes	hasil dari 90 citra yang terdiri 10 kualitas bagus kelas 1, 10 kualitas bagus kelas 2, dan 10 kualitas tidak bagus didapat akurasi terbaik, dengan total akurasi sebesar 80%.
10.	Otomatisasi Klasifikasi Kematangan Buah Mengkudu Berdasarkan Warna Dan Tekstur	Selvia Ferdiana Kusuma, Ratri Enggar Pawening, Rohman Dijaya	2017	Metode yang digunakan untuk klasifikasi adalah KNN dan SVM	Hasil presentase tertinggi sebesar 87,22%.

2.2 Klasifikasi

Klasifikasi adalah penyusunan bersistem dalam kelompok atau golongan yang ditetapkan. Selain itu klasifikasi adalah pengelompokan berdasarkan ciri dan pola masing-masing objek. Teknik klasifikasi pengelompokannya bukan berdasarkan jarak, melainkan berdasarkan ciri dan pola yang sama pada masing-masing objek. Serta pengelompokannya harus detail, pertama ditentukan kelas misal (Bagus, Cukup, Kurang Bagus), ketiga kelas tersebut harus memiliki ciri-ciri bagaimana sebuah objek dapat dikatakan (Bagus) masuk pada kelompok

Bagus. Maka tentunya kelas Bagus harus memiliki ciri/kriteria. Klasifikasi tidak dapat melakukan pengelompokan secara langsung, untuk itu klasifikasi tergolong teknik yang membutuhkan peatihan data terlebih dahulu. Konsep ini biasa disebut dengan labeling.

Klasifikasi merupakan pengelompokan sample berdasarkan ciri-ciri persamaan atau perbedaan dengan menggunakan variable target sebagai kategori. Komponen dari klasifikasi yaitu:

- a. Kelas, hasil pengelompokan suatu data dari proses klasifikasi
- b. Data Pelatihan merupakan sekumpulan data lengkap untuk dilatih agar dapat mengelompokkan ke dalam suatu kelas .

2.3 Citra Digital

2.3.1 Pengertian Citra Digital

Citra digital adalah suatu representasi kemiripan atau imitasi objek atau ilmu yang akan mempelajari cara tentang bagaimana citra di bentuk, di olah, dan di analisis sehingga menghasilkan suatu informasi yang mudah di pahami. Citra terbagi menjadi dua yaitu citra analog dan citra digital. Citra analog adalah citra yang terbentuk dari frekwensi analog atau pengolahannya tidak bisa langsung ke dalam komputer, sedangkan citra digital adalah citra yang di ambil oleh mesin dengan pendekatan atau bisa diolah langsung ke dalam komputer.

2.3.2 Pengertian Pengolahan Citra Digital

Secara umum, pengolahan citra digital menunjuk pada pemrosesan gambar dua dimensi menggunakan komputer. Dalam konteks yang lebih luas, pengolahan citra digital mengacu pada pemrosesan setiap data dua dimensi. Citra digital merupakan sebuah larik yang berisi nilai-nilai real maupun kompleks yang direpresentasikan dengan deretan bit tertentu. Citra digital dapat didefinisikan secara matematis sebagai fungsi intensitas dalam 2 variable x dan y , yang dapat dituliskan $f(x,y)$, dimana (x,y) merepresentasikan koordinat spasial pada bidang 2 dimensi dan $f(x,y)$ merupakan intensitas cahaya pada kordinat tersebut. Citra digital merupakan representasi citra asal yang bersifat kontinyu. Untuk mengubah

citra yang bersifat kontinyu diperlukan sebuah cara untuk mengubahnya dalam bentuk data digital. Komputer menggunakan sistem bilangan biner untuk memecahkan masalah ini. Dengan menggunakan sistem bilangan biner ini, citra dapat diproses dalam komputer dengan sebelumnya mengekstrak informasi citra analog asli dan mengirimnya ke komputer dalam bentuk biner. Proses ini disebut dengan digitalisasi.

2.4 Jenis Citra Digital

2.4.1 Citra Biner

Citra biner (binary image) adalah citra digital yang hanya memiliki 2 kemungkinan warna, yaitu hitam dan putih. Citra biner disebut juga dengan citra W&B (White&Black) atau citra monokrom. Hanya dibutuhkan 1 bit untuk mewakili nilai setiap piksel dari citra biner. Pembentukan citra biner memerlukan nilai batas keabuan yang akan digunakan sebagai nilai patokan. Piksel dengan derajat keabuan lebih besar dari nilai batas akan diberi nilai 1 dan sebaliknya piksel dengan derajat keabuan lebih kecil dari nilai batas akan diberi nilai 0. Citra biner sering sekali muncul sebagai hasil dari proses pengolahan, seperti segmentasi, pengambangan, morfologi ataupun dithering. Fungsi dari binerisasi sendiri adalah untuk mempermudah proses pengenalan pola, karena pola akan lebih mudah terdeteksi pada citra yang mengandung lebih sedikit warna.

2.4.2 Citra RGB

Red (Merah), Green (Hijau) dan Blue (Biru) merupakan warna dasar yang dapat diterima oleh mata manusia. Setiap piksel pada citra warna mewakili warna yang merupakan kombinasi dari ketiga warna dasar RGB. Setiap titik pada citra warna membutuhkan data sebesar 3 byte. Setiap warna dasar memiliki intensitas tersendiri dengan nilai minimum nol (0) dan nilai maksimum 255 (8 bit). RGB didasarkan pada teori bahwa mata manusia peka terhadap panjang gelombang 630nm (merah), 530 nm (hijau), dan 450 nm (biru).

2.4.3 Citra Grayscale

Citra grayscale merupakan citra digital yang hanya memiliki satu nilai kanal pada setiap pikselnya, artinya nilai dari Red = Green = Blue. Nilai-nilai tersebut

digunakan untuk menunjukkan intensitas warna. Citra yang ditampilkan dari citra jenis ini terdiri atas warna abu-abu, bervariasi pada warna hitam pada bagian yang intensitas terlemah dan warna putih pada intensitas terkuat. Citra grayscale berbeda dengan citra "hitam-putih", dimana pada konteks komputer, citra hitam putih hanya terdiri atas 2 warna saja yaitu "hitam" dan "putih" saja. Pada citra grayscale warna bervariasi antara hitam dan putih, tetapi variasi warna diantaranya sangat banyak. Citra grayscale seringkali merupakan perhitungan dari intensitas cahaya pada setiap piksel pada spektrum elektromagnetik single band. Citra grayscale disimpan dalam format 8 bit untuk setiap sample piksel, yang memungkinkan sebanyak 256 intensitas. Untuk mengubah citra berwarna yang mempunyai nilai matrik masing-masing R, G dan B menjadi citra grayscale dengan nilai X, maka konversi dapat dilakukan dengan mengambil rata-rata dari nilai R, G dan B.

2.5 Matlab

MATLAB adalah sebuah bahasa dengan kinerja tinggi untuk komputasi masalah teknik. Matlab mengintegrasikan komputasi, visualisasi, dan pemrograman dalam suatu model yang sangat mudah untuk dipakai dimana masalah-masalah dan penyelesaiannya diekspresikan dalam notasi matematika yang familiar. Penggunaan Matlab meliputi bidang-bidang:

- Matematika dan Komputasi
- Pembentukan Algoritma
- Akuisisi Data
- Pemodelan, simulasi, dan pembuatan prototipe
- Analisa data, explorasi, dan visualisasi
- Grafik Keilmuan dan bidang Rekayasa

Fitur-fitur MATLAB sudah banyak dikembangkan, dan lebih kita kenal dengan nama toolbox. Toolbox ini merupakan kumpulan dari fungsi-fungsi MATLAB (M-files) yang telah dikembangkan ke suatu lingkungan kerja untuk memecahkan masalah dalam kelas particular. Area yang sudah bisa dipecahkan dengan toolbox saat ini meliputi pengolahan sinyal, system kontrol, *neural*

networks, fuzzy logic, wavelets, dan lain-lain. Kelengkapan pada Sistem MATLAB Sebagai sebuah system, MATLAB tersusun dari 5 bagian utama:

1. *Development Environment*. Merupakan sekumpulan perangkat dan fasilitas yang membantu untuk menggunakan fungsi-fungsi dan file-file MATLAB. Perangkat ini merupakan sebuah *graphical user interfaces* (GUI). Termasuk didalamnya adalah MATLAB desktop dan *Command Window, command history*, sebuah editor dan debugger, dan browsers untuk melihat *help, workspace, files*, dan *search path*.
2. *MATLAB Mathematical Function Library*. Merupakan sekumpulan algoritma komputasi mulai dari fungsi dasar seperti: *sum, sin, cos*, dan *complex arithmetic*, sampai dengan fungsi yang lebih kompleks seperti *matrix inverse, matrix eigenvalues, Bessel functions*, dan *fast Fourier transforms*.
3. *MATLAB Language*. Merupakan suatu high-level matrix/array language dengan control flow statements, functions, data structures, input/output, dan fitur-fitur object-oriented programming.
4. MATLAB memiliki fasilitas untuk menampilkan vector dan matrices sebagai suatu grafik. Didalamnya melibatkan high-level functions (fungsi-fungsi level tinggi) untuk visualisasi data dua dimensi dan data tiga dimensi, *image processing, animation*, dan *presentation graphics*.
5. *MATLAB Application Program Interface (API)*. Merupakan suatu library yang memungkinkan program yang telah anda tulis dalam bahasa C mampu berinteraksi dengan MATLAB. Ini melibatkan fasilitas untuk pemanggilan routines dari MATLAB (dynamic linking), pemanggilan MATLAB sebagai sebuah computational engine, dan untuk membaca dan menuliskan MAT-files.

2.6 K-Nearest Neighbor

K-Nearest Neighbor (KNN) adalah algoritma yang digunakan untuk melakukan proses klasifikasi berdasarkan dari data training yang diperoleh dari k tetangga terdekat (nearest neighbors). Tujuan dari algoritma KNN adalah

mengklasifikasikan objek baru berdasarkan atribut dan sampel-sampel dari data training. Termasuk dalam supervised learning, dimana hasil query instance yang baru diklasifikasikan berdasarkan mayoritas kedekatan jarak dari kategori yang ada dalam KNN. Konsep dasar dari KNN adalah mencari jarak terdekat antara data yang akan dievaluasi dengan k tetangga terdekatnya dalam data latih. Perhitungan jarak dilakukan dengan menggunakan konsep Euclidean. Jumlah kelas paling yang paling banyak dengan jarak terdekat tersebut akan menjadi kelas dimana data evaluasi tersebut berada.

Berikut adalah rumus Euclidean Persamaan 2.1 digunakan untuk menghitung tetangga terdekat atau tetangga jauh berdasarkan jarak:

$$d(x, y) = \|x - y\| = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (2.1)$$

Berikut adalah contoh Algoritma perhitungan KNN:

1. Menentukan parameter K sebagai banyaknya jumlah tetangga terdekat dengan objek baru.
2. Menghitung jarak antar objek/data baru terhadap semua objek/data yang telah di training.
3. Mengurutkan hasil perhitungan tersebut.
4. Menentukan tetangga terdekat berdasarkan jarak minimum ke K.
5. Menentukan kategori dari tetangga terdekat dengan objek atau data.
6. Menggunakan kategori mayoritas sebagai klasifikasi objek atau data baru.

2.7 *Gray Level Co-occurrence Matrix (GLCM)*

Gray Level Co-occurrence Matrix (GLCM) adalah suatu matrik kookurensi yang elemen-elemennya merupakan jumlah piksel-piksel untuk menganalisis fitur tekstur terhadap suatu ciri pada citra sehingga dapat mengetahui tingkat keabuan yang terjadi. Atau bisa dijelaskan sebagai salah satu ekstraksi order kedua pada fitur tekstur. Ekstraksi order kedua menunjukkan hubungan statistik antara 2 piksel. GLCM adalah sebuah matriks dengan jumlah baris kolom sebanding dengan

jumlah *gray level* (G) dalam suatu citra, metode GLCM menggunakan citra berskala keabuan (*grayscale*). Rumus matriks GLCM dapat dilihat pada persamaan 2.2

$$GLCM \xrightarrow{r} (i, j) = \left\{ \begin{array}{l} (x_1, y_1), (x_2, y_2) \in (N_x, N_y) \times (N_x, N_y) \\ f(x_1, y_1) = i \wedge f(x_2, y_2) = j \wedge \vec{r} = (x_2 - x_1, y_2 - y_1) \end{array} \right\} \quad (2.2)$$

Sebagai contoh, matriks G adalah matriks referensi yang berupa citra *grayscale*. Nilai (i,j) merupakan nilai intensitas piksel. Dengan begitu, matriks GLCM adalah matriks frekuensi dengan elemen (i,j) merupakan jumlah dari hubungan ketetanggaan nilai piksel i dengan jarak dan sudut tertentu (\vec{r}) terhadap nilai piksel j. Jumlah baris dan kolom matriks GLCM bergantung pada tingkat keabuan suatu citra. Karena nilai tingkat keabuan (*grayscale*) suatu citra antara 0 hingga 255, matriks GLCM bisa memiliki baris dan kolom sebesar 256 x 256.

Untuk mendapatkan hasil ekstraksi ciri GLCM ada 2 hal yang perlu dilakukan. Pertama ialah memasang piksel *co-occurences* spasial yang dipisahkan oleh sudut dan jarak tertentu yang ditabulasi menggunakan GLCM. Kedua ialah GLCM digunakan untuk menghitung kuantitas skalar yang memiliki karakteristik dengan aspek berbeda sesuai tekstur. Nilai kuantitas ini adalah hasil ekstraksi ciri GLCM yang digunakan untuk mengklasifikasi suatu tekstur. Beberapa fitur yang digunakan dalam penelitian ini yaitu:

a. Energy

Energy atau bisa disebut juga dengan ASM adalah penjumlahan pangkat dari elemen GLCM. *Energy* memiliki nilai tinggi ketika citra memiliki *homogeneity* yang baik. Untuk mencari fitur *energy* atau ASM dapat menggunakan rumus sebagai berikut. 2.3

$$energy = \sum_{i=1}^L \sum_{j=1}^L (GLCM(i, j))^2 \quad (2.3)$$

b. Korelasi

Korelasi merupakan ketidak teraturan dari ukuran bentuk, jika nilai Entropinya besar untuk citra dengan transisi nilai derajat keabuan yang teratur, dan bernilai kecil jika struktur citra tidak teratur (bervariasi) atau mengukur ketergantungan linear dari aras keabuan dalam ketetanggaan piksel citra. Untuk mencari nilai korelasi dapat menggunakan rumus sebagai berikut. 2.4

$$korelasi = \sum_{i=1}^L \sum_{j=1}^L \frac{(i - \mu_{i'}) * (j - \mu_{j'}) * GLCM(i, j)}{\sigma_{i'} * \sigma_{j'}} \quad (2.4)$$

c. Kontras

Kontras biasa juga disebut dengan *inertia* adalah suatu ukuran intensitas aras keabuan antara piksel 1 dengan piksel lainnya dengan relatif. Kontras mempunyai nilai batasan dari 0 hingga pangkat 2 dari panjang GLCM simetris. Untuk mencari nilai kontras menggunakan rumus sebagai berikut. 2.5

$$kontras = \sum_{i=1}^L \sum_{j=1}^L (i - j)^2 GLCM(i, j) \quad (2.5)$$

d. Homogeneity

Homogeneity atau bisa disebut juga dengan IDM, di gunakan untuk mengukur kehomogenan variasi intensitas citra. Nilai homogenitas (H) dapat dihitung dengan persamaan. *Homogeneity* berkaitan dengan kontras, bobot *homogeneity* merupakan kebalikan dari bobot kontras. Untuk mencari nilai *homogeneity* menggunakan rumus sebagai berikut 2.6

$$homogeneity = \sum_{i=1}^L \sum_{j=1}^L \frac{GLCM(i, j)}{1 + (i - j)^2} \quad (2.6)$$

2.8 Area, Perimeter, Major Axis Length & Minor Axis Length

Area, perimeter, major axis length, dan minor axis length merupakan parameter-parameter untuk mengekstraksi fitur suatu objek pada citra berdasarkan bentuk objek tersebut. Area merupakan nilai luas dari objek dalam suatu citra. Area dari suatu objek didapat dengan menghitung banyaknya piksel yang menyusun objek tersebut, sedangkan perimeter adalah keliling yang

merupakan banyaknya piksel yang mengelilingi suatu objek. Major axis length merupakan garis segmentasi lurus yang menggabungkan dua titik lurus yang terjauh. Sedangkan minor axis length adalah garis yang terletak tegak lurus dengan major axis.

2.9 Mean

Nilai rata-rata dari intensitas di dalam citra atau yang disebut dengan mean merupakan fitur yang sangat umum dalam statistika sebagai nilai yang diharapkan untuk mencirikan suatu citra dan perhitungannya tidak membutuhkan pembentukan matriks co-occurrence terlebih dahulu.

2.10 Skewness

Skewness atau yang disebut kecondongan merupakan derajat ketidak simetrisan distribusi warna dari citra, yang dilihat dari nilai-nilai histogram citra tersebut. Jika kurva frekuensi suatu distribusi warna memiliki ekor yang lebih memanjang ke kanan (dilihat dari meannya) maka dikatakan menceng kanan (positif) dan jika sebaliknya dikatakan menceng kiri (negatif). Secara matematis skewness adalah momen ke tiga dari mean. Jika kurva distribusi berbentuk normal maka nilai skewnessnya adalah nol.