

Machine Learning Untuk Estimasi Posisi Objek Berbasis RSS Fingerprint Menggunakan IEEE 802.11g Pada Lantai 3 Gedung JTETI UGM

¹Chairani, ²Widyawan, ³Sri Suning Kusumawardani

¹Jurusan Teknik Informatika, IBI Darmajaya

^{2,3}Jurusan Teknik Elektro dan Teknologi Informasi Universitas Gadjah Mada

¹Jl. A. Pagar Alam, No. 93, Bandar Lampung, Indonesia

^{2,3}Jln. Grafika 2 Yogyakarta 55281 Indonesia

chairani.fauzi.fathir@gmail.com, widyawan@ugm.ac.id, suning@mti.ugm.ac.id

Abstrak - Penelitian ini membahas tentang estimasi posisi (*localization*) objek dalam gedung menggunakan jaringan *wireless* atau IEEE 802.11g dengan pendekatan *Machine Learning*. Metode pada pengukuran *RSS* menggunakan *RSS-based fingerprint*. Algoritma *Machine Learning* yang digunakan dalam memperkirakan lokasi dari pengukuran *RSS-based* menggunakan *Naive Bayes*. *Localization* dilakukan pada lantai 3 gedung Jurusan Teknik Elektro dan Teknologi Informasi (JTETI) dengan luas 1969,68 m² dan memiliki 5 buah titik penempatan *access point* (AP). Untuk membentuk peta *fingerprint* digunakan dimensi 1 m x 1 m sehingga terbentuk *grid* sebanyak 1893 buah. Dengan menggunakan *software Net Surveyor* terkumpul data kekuatan sinyal yang diterima (RSS) dari jaringan *wireless* ke perangkat penerima (laptop) sebanyak 86.980 *record*. Hasil nilai rata-rata *error* jarak estimasi untuk *localization* seluruh ruangan di lantai 3 dengan menggunakan algoritma *Naive Bayes* pada fase *offline* tahap *learning* adalah 6,29 meter. Untuk fase *online* dan tahap *post learning* diperoleh rata-rata *error* jarak estimasi sebesar 7,82 meter.

Kata kunci - *Localization dalam gedung, IEEE 802.11g, Received Signal Strength (RSS), Fingerprint, Naive Bayes*

Abstract - This research discuss about object position estimation (*localization*) inside the building using wireless network or IEEE 802.11g with machine learning approach. Measurement method of RSS using RSS-based fingerprint. Machine learning algorithm used to estimate the location of measuring RSS-based with Naive Bayes.

The localization conducted in third floor at Electronic Engineering and Information Technology Departement (JTETI) with 1969,68 m² area and 5 point of access point placement. To build fingerprint map, we use 1m x 1m dimension thus formed 1983 grids. Using Net Surveyor software, received signal strength from wireless to receiver device gathered 86,980 record.

Mean distance estimation error value for the localization for whole room at third floor using Naïve Bayes algorithim in offline phase of learning stage is 6.29 meter. From online phase of learning stage resulting mean distance error 7.82 meter.

Keyword - Indoor Localization, IEEE 802.11g, Received Signal Strength (RSS), Fingerprint, Naive Bayes

I. PENDAHULUAN

Sistem penentuan posisi (*localization*) adalah teknologi utama untuk membangun ruang komputasi *pervasif* yang cerdas [1]. *Localization* merupakan salah satu bidang yang masuk kedalam ruang lingkup klasifikasi. Klasifikasi merupakan salah satu masalah yang dapat ditangani dengan menggunakan metode *machine learning*. Keunggulan dari penggunaan metode *machine learning* adalah karena kesederhanaannya dalam melakukan proses pembelajaran [12].

Localization digunakan untuk memprediksi lokasi dari perangkat *mobile* berdasarkan nilai-nilai data yang terukur. Lokasi dapat diwakili oleh (x, y) untuk bentuk dua dimensi, dimana x dan y merupakan koresponden masing-masing nilai koordinat x dan y.

Sistem *localization* secara umum bertujuan untuk memperkirakan lokasi perangkat *mobile* berdasarkan nilai-nilai data terukur yang dikumpulkan dalam sebuah vektor yang diterima oleh perangkat *mobile* [11].

Ada beberapa teknologi yang dapat digunakan dalam membangun sistem *localization*, baik di luar gedung (*outdoor*) maupun di dalam gedung (*indoor*). Keberhasilan *localization* di luar gedung dan aplikasi berbasis *Global Positioning System* (GPS) menyediakan ruang untuk penelitian dan pengembangan sistem penentuan posisi dalam ruangan [14]. Keuntungan utama dari sistem GPS bisa mendapatkan posisi melalui sinyal dari satelit dan memiliki cara kerja dimana penerima harus berada pada posisi *line of sight*. Hal tersebut menjadikan sistem GPS tidak dapat digunakan secara efektif di

dalam gedung karena penerimaan sinyal yang lemah [14]. GPS cocok digunakan pada area luar gedung atau lingkungan *outdoor* dengan tingkat kesalahan 5 meter sampai dengan 10 meter [13]. Teknologi lainnya adalah *Cellphone*. *Cellphone* cocok untuk lingkungan *outdoor* dengan prinsip *telephone trunk* yang memiliki akurasi 50 meter dengan biaya yang *moderate*. Namun, akurasi dari sistem posisi berbasis GSM dalam ruangan sangat dibatasi oleh ukuran sel atau *CELL-ID* [13]. GPS dan *Cellphone* (GSM) memiliki keterbatasan dalam efektivitas sistem untuk lingkungan dalam ruangan yang disebabkan oleh *multipath* dan pelemahan sinyal [15].

Teknologi yang dapat digunakan untuk membangun sistem posisi dalam gedung antara lain *Bluetooth*, *RFID*, *Zigbee*, *UWB* dan *IEEE 802.11*. *Bluetooth* memiliki tingkat akurasi 2 meter untuk *localization* dalam gedung dan memiliki skalabilitas atau jarak dimensi penempatan *nodes* setiap 2 meter sampai dengan 15 meter agar memperoleh tingkat akurasi maksimum. *RFID* memiliki akurasi kurang dari 2 meter dengan skalabilitas pemasangan *nodes* secara *densely*. *UWB* merupakan teknologi yang memiliki tingkat biaya yang tinggi dengan tingkat akurasi 15 sentimeter, dengan skalabilitas penempatan sensor antara 2 sampai 4 buah sensor per *cell* (100-1000m). *WLAN* atau *IEEE 802.11* memiliki tingkat akurasi antara 3 meter sampai dengan 5 meter, serta memiliki skalabilitas yang baik untuk 2D/3D [10].

Peningkatan penyebaran *IEEE 802.11b/g* atau *WLAN* oleh banyak individu dan organisasi baik dalam rumah, kantor, bangunan, dan kampus telah menjadikan popularitas *WLAN* begitu tinggi. Infrastruktur *WLAN* juga dapat diterapkan untuk memberikan layanan lokasi dalam ruangan tanpa menggunakan peralatan tambahan [14]. Hal ini dapat terlihat dengan adanya berbagai area aplikasi yang dibutuhkan oleh pengguna secara luas dengan menggunakan teknologi *WLAN* (misalnya area aplikasi konsumen, medis, industri, keselamatan umum, logistik, dan sistem transportasi bersama dengan aplikasi lainnya).

Localization dalam gedung dengan penggunaan teknologi *IEEE 802.11* atau *WLAN* menggunakan teknik *fingerprint*, hal ini dikarenakan ketika hubungan analitis antara pengukuran RSS dan jarak tidak mudah dibentuk karena *multipath* dan interferensi [2]. Keunggulan jenis sistem posisi berbasis *fingerprint* antara lain tidak memerlukan *hardware* khusus selain antarmuka jaringan yang umum seperti nirkabel dengan kemampuan pengukuran RSS, oleh karena itu relatif mudah diimplementasikan dibandingkan dengan teknik lain. Keuntungan lainnya adalah lokasi *fingerprint* juga bisa diimplementasikan sebagai *positioning system* berbasis *software* yang dapat mengurangi kompleksitas dan biaya. Setiap infrastruktur *WLAN* yang ada dapat digunakan kembali untuk *positioning*

system. Sistem penentuan posisi tersebut dipandang sebagai solusi yang paling efektif dan layak untuk lingkungan *indoor* [8][9].

Karena teknologi GPS kurang efektif untuk digunakan pada sistem *localization* dalam gedung, serta penggunaan teknologi *RFID*, *Zigbee*, serta *UWB* untuk sistem *localization* memerlukan biaya yang besar dalam membangun infrastruktur untuk *localization* dalam gedung, maka dibuatlah sistem *localization* dengan menggunakan *WLAN* atau *IEEE 802.11* untuk mengestimasi lokasi dengan menggunakan pendekatan *machine learning*.

WLAN digunakan karena memiliki beberapa keunggulan antara lain kekuatan sinyal (*signal strength*) yang dapat menembus dinding sehingga sistem dapat digunakan dilebih dari satu ruangan, sangat mudah dan cepat untuk diinstal, memiliki tingkat biaya yang lebih rendah daripada teknologi lainnya, dapat digunakan di tempat-tempat yang bersifat *indoor* maupun *outdoor*, memiliki sistem yang memungkinkan jumlah pengguna yang tinggi [7], memiliki jangkauan sinyal yang cukup besar untuk area lokal terhadap orang yang menggunakan teknologi *wireless* dalam kehidupan sehari-hari terutama di kantor, serta teknologi yang bersifat *off the shelf*. Dengan biaya yang rendah serta sudah adanya dukungan infrastruktur dalam gedung, teknologi *WLAN* dapat dimanfaatkan dalam membangun sistem *localization* dalam gedung untuk mengetahui tingkat akurasi dari estimasi posisi dalam gedung

II. METODOLOGI PENELITIAN

A. Metode Kajian

Pada *indoor localization* tahapan-tahapan dalam metode *machine learning* terdiri dari (Gambar 1) [5]:

1. Tahap Pre-Learning

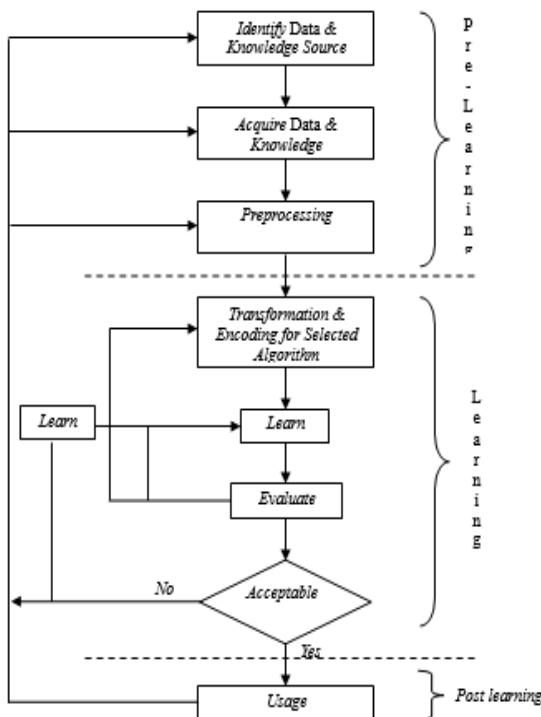
a. Tahap identifikasi data dan *knowledge source* merupakan tahapan spesifikasi parameter sistem pengukuran nilai RSS dari *multiple access point* yang ada di gedung Teknik Elektro. Proses pengukuran dilakukan dengan mengabaikan adanya efek *multipath* dan propagasi.

b. Tahap *acquire* data dan *knowledge* merupakan tahapan penetapan lokasi *fingerprint* yang akan diukur dalam gedung dengan menetapkan *grid* atau titik-titik pengukuran (*predefined*) dalam bentuk koordinat (x,y).

c. Tahap *preprocessing*

Merupakan tahap pemrosesan data dari langkah (b). *Preprocessing* dilakukan dengan menghilangkan RSS *WLAN* dan *atribute access point* yang berada diluar area Teknik Elektro dan Teknologi Informasi (JTETI) UGM Lantai 3 meskipun sinyal tersebut tertangkap. Pada tahap

preprocessing akan dibuat juga database *fingerprint* RSS WLAN. Database *fingerprint* ini kemudian diolah untuk menghasilkan Visualisasi peta *fingerprint*.



Gambar 1. Metode Machine Learning

2. Tahap Learning

Merupakan tahapan proses pembelajaran pengenalan posisi yang dilakukan terhadap database *fingerprint* dengan menggunakan algoritma *Naive Bayes*.

B. Teknik Localization

Teknik *localization* (Gambar 2) terdiri dari dua buah fase, yaitu fase *offline* dan fase *online*. Fase *offline* merupakan proses dilakukannya pengukuran *Received Signal Strength (RSS)* dari *multiple access point (AP)* yang berfungsi untuk membangun database yang disebut sebagai peta radio untuk lingkungan target (*database fingerprint*).

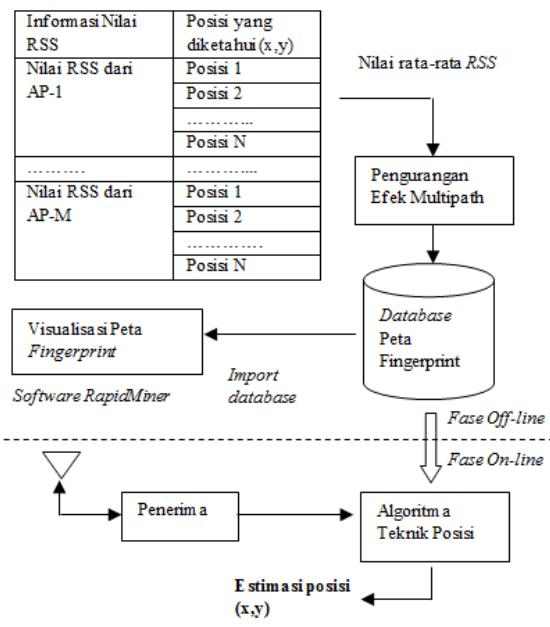
Fase *online* dilakukan untuk menghitung lokasi dengan cara membandingkan *RSS* diukur dengan *RSS* yang disimpan dalam *database*. Pada tahap *online* dikenal dengan teknik posisi karena pada tahap ini dilakukan pengukuran *RSS* secara *real time* oleh penerima kemudian menghitung koordinat lokasi yang diperkirakan berdasarkan *database* peta radio dengan menggunakan algoritma posisi.

C. Metode Penyimpulan Lokasi Yang Telah Diidentifikasi

RSS adalah kekuatan sinyal yang diterima oleh penerima jarak jauh dari pemancar. Secara umum, *RSS* menurun secara proporsional dengan jarak. Jika

hubungan jarak kekuatan sinyal diketahui, baik analitis atau empiris, jarak antara dua perangkat dapat dihitung. Ada beberapa keuntungan menggunakan *RSS* untuk *localization* dalam gedung. Pertama, dapat diimplementasikan dalam sistem komunikasi nirkabel dengan tidak ada perubahan pada perangkat keras atau sedikit perubahan pada perangkat keras. Kedua, tidak memerlukan sinkronisasi antara pemancar dan penerima. Keuntungan ini merupakan faktor utama yang berkontribusi terhadap keterjangkauan yang lebih besar dan penggunaan *RSS* untuk *localization* dalam gedung. Kekurangan utama adalah bahwa pembacaan *RSS* dapat menunjukkan variasi besar karena interferensi dan *multipath* pada saluran radio [13]. Gambar 2 merupakan arsitektur sistem *localization* dalam gedung.

Pengukuran nilai *RSS* dari *multiple access point* yang ada di gedung Teknik Elektro dan Teknologi Informasi (JTETI) UGM dilakukan dengan mengabaikan adanya efek *multipath* dan propagasi, dengan menetapkan lokasi *fingerprint* yang akan diukur dalam gedung berupa penetapan *grid* atau titik-titik pengukuran (*predefined*) dalam bentuk koordinat (x,y). Penetapan *grid* menggunakan ukuran 1 m x 1 m. Tahap pengukuran *RSS* dilakukan dengan menggunakan *software NetSurveyor* (Gambar 3). Pengukuran dilakukan pada titik tengah masing-masing *grid*. Preprosesing data dilakukan dengan memilih *atribute access point* dan nilai *RSS* yang sesuai dengan penggunaan AP.



Gambar 3. Arsitektur sistem *localization*

Hasil seluruh rata-rata dari masing-masing *grid* yang telah ditetapkan nilai koordinatnya kemudian disimpan dalam *database fingerprint*. *Database fingerprint* diimpor kedalam program *RapidMiner* dengan menetapkan *atribute class* yang berisi titik koordinat x dan y. *Database fingerprint* ini kemudian diolah untuk menghasilkan visualisasi peta

fingerprint.

D. Pengolahan Data Terukur

Fingerprinting adalah metode untuk pemetaan data yang terukur (misalnya *RSS*) ke dalam titik-grid yang meliputi seluruh cakupan wilayah *localization*. Lokasi diperkirakan dari perbandingan antara pengukuran *RSS real-time* dan *RSS* yang sebelumnya disimpan dalam *fingerprint*. *Fingerprinting* sering digunakan untuk *localization* berbasis dalam gedung atau dalam ruangan, terutama ketika hubungan analitis antara pengukuran *RSS* dan jarak tidak mudah dibentuk karena *multipath* dan interferensi [2].

Model sistem posisi dalam ruangan dan lokasi *fingerprint*s dapat dinyatakan sebagai sebuah vektor $F = (\rho_1, \rho_2, \rho_3, \dots, \rho_n)$ elemen rata-rata *RSS*. Untuk satu lokasi area *fingerprint* maka *fingerprint* lokasi adalah $\{F_1, F_2, F_3, \dots, F_n\}$. Pengukuran *RSS* *fingerprint* selama fase *off-line* dinotasikan sebagai S yang dapat dijadikan sebagai *mean* atau rata-rata sampel *RSS* yang diperoleh dari pengukuran *RSS* berdasarkan durasi waktu yang tidak terlalu lama [8][9].

Sistem posisi dalam ruangan menganggap nilai rata-rata *RSS* dari N APs sebagai lokasi *fingerprint* $[F_i = (\rho_1^i, \rho_2^i, \rho_3^i, \dots, \rho_N^i)]$ sampel dari vektor *RSS*

$S = s_1, s_2, s_3, \dots, s_n$ dan setiap *fingerprint* lokasi i didalam *database* dapat dinotasikan sebagai L . Setiap *fingerprint* merupakan pemetaan *one-to-one* ke sebuah set posisi $\{L_1, L_2, L_3, \dots, L_n\}$. Informasi lokasi L sebagai sistem koordinat dua atau tiga dimensi dan dapat digunakan orientasi pada *mobile station's* misal dapat menghadap utara, selatan, barat, atau timur [8][9]. Dalam penelitian ini, penulis menggunakan dua dimensi dalam sistem koordinat dan hanya menggunakan satu orientasi dalam melakukan koleksi *fingerprint*, yaitu dengan arah pengukuran menghadap utara.

Propagasi sinyal dalam ruangan sangatlah kompleks. Isu yang paling menantang dari WLAN *Fingerprint* adalah nilai *RSS* WLAN yang tidak stabil tiap kali dilakukan pengukuran. Hal ini dikarenakan adanya efek *multipath* (yang disebabkan oleh refleksi, difraksi, dan difusi). Efek *multipath* dapat ditangani dengan merata-ratakan nilai *RSS* [6]. Sehingga untuk mengurangi *noise* dari sebaran sinyal WLAN digunakan perhitungan rata-rata dari nilai *RSS* yang telah diukur selama ± 1 menit 56 detik dengan menggunakan persamaan (1) dan persamaan (2).



Gambar 4. Pengukuran *RSS* Menggunakan *Software Net Surveyor*

$$TA_RSS^m = A[y^m(n)] \quad (1)$$

$$= \frac{1}{N} \sum_{n=0}^{N-1} y^m(n) \quad (2)$$

Dengan y merupakan nilai *RSS* diukur dari m di lokasi yang tetap, m adalah indeks dari AP, $m=0, 1, 2, 3, \dots, m-1$. n merupakan indeks waktu diskrit, dan A merupakan proses rata-rata terhadap waktu yang indeksnya- n , dan N menunjukkan panjang dari urutan waktu.

Hasil seluruh rata-rata dari masing-masing *grid* yang telah ditetapkan nilai koordinatnya kemudian disimpan dalam *database* *fingerprint*. *Database* *fingerprint* diimpor kedalam program RapidMiner dengan menetapkan *atribute class* yang berisi titik koordinat x dan y . *Database* *fingerprint* ini kemudian diolah untuk menghasilkan visualisasi peta *fingerprint*.

E. Algoritma Machine Learning Untuk Teknik Posisi

1. Algoritma Naive Bayes

Naive Bayes Classifier merupakan algoritma klasifikasi yang berdasarkan pada teorema bayes. Algoritma posisi *fingerprint* menggunakan pendekatan probabilistik seperti *maximum likelihood* (ML). ML diadopsi menjadi algoritma posisi, dengan penjelasan sebagai berikut: [3].

Perangkat *mobile* akan menerima sebuah *set signature* sinyal dari *access point* (AP), yaitu $A_n = \{AP_1, AP_2, AP_3, \dots, AP_n\}$, dengan AP_a adalah AP ($1 \leq a \leq n$) dan n adalah nomor APs dalam gedung. ss_a merupakan kekuatan sinyal yang diterima oleh perangkat penerima (laptop) dari AP_a ($1 \leq a \leq n$). Jika perangkat mobile tidak dapat menerima sinyal dari AP_a maka akan diberikan kekuatan sinyalnya menjadi -100 dbm. Nilai *RSS* yang diterima pada fase *on-line* oleh perangkat penerima dapat dituliskan sebagai sebuah vektor $S = [ss_1, ss_2, ss_3, \dots, ss_n]^T$. *RSS* dari setiap referensi titik akan dimodelkan kedalam *Gaussian Distribution* (persamaan (5)), sehingga estimasi *likelihood* menjadi *practicable*. Total titik

(points) direpresentasikan sebagai set R dan $|R| = N$. $RP_x = [rp_1^x, rp_2^x, rp_3^x, \dots, rp_n^x]$ merupakan sebuah vektor RSS yang diterima dari n APs pada referensi titik ke-x, dan $\Delta_x = [\Delta_1^x, \Delta_2^x, \Delta_3^x, \dots, \Delta_n^x]$ sebagai vektor standar deviasi pada referensi titik x.

Dasar penentuan *localization* adalah mencari P probabilitas tertinggi $P(x|S)$ dimana RSS diukur sebagai S, titik acuan x dengan probability tertinggi $P(x|S)$ berarti bahwa kekuatan sinyal dari x adalah yang paling mirip dengan sinyal yang diukur dari perangkat *mobile*. Menurut aturan *Bayes* probabilitas dapat dihitung:

$$P(x|S) = \frac{P(x|S)P(x)}{P(S)} = CxP(S|x) \quad (3)$$

dengan C adalah skala konstan jika x mengikuti distribusi normal. Oleh karena itu, nilai $P(x|S)$ tergantung pada nilai $P(S|x)$. dengan demikian, titik x referensi dikatakan lokasi perangkat *mobile* jika probabilitas $P(S|x)$ adalah yang tertinggi.

Persamaan (4) digunakan untuk mencari perkiraan koordinat sebagai rata-rata semua lokasi dengan mengadopsi kemungkinan normalisasi sebagai bobot untuk memberikan hasil yang lebih akurat.

$$x' = \sum x = \frac{P(S|x)}{\sum_{x \in R} P(S|x)} \quad (4)$$

Karena RSS diukur pada setiap titik acuan maka dapat dimodelkan sebagai *distribution Gaussian*, probabilitas $P(S|x)$ dapat dihitung sebagai.

$$P(S|x) = \frac{1}{\prod_a \sqrt{2\pi(\Delta_a^x)^2}} \exp\left\{-\frac{(ss_a - rp_a^x)^2}{2(\Delta_a^x)^2}\right\} \quad (5)$$

F. Perhitungan Nilai Akurasi Dari Estimasi Localization

Akurasi (*location error*) merupakan hal penting didalam sistem posisi. Biasanya, *mean distance error* digunakan sebagai penghitungan *performance metric* yang diperoleh dengan mencari rata-rata *euclidean distance* antara estimasi lokasi dan lokasi sebenarnya [10].

Untuk menghitung nilai akurasi (*location error*) dilakukan dengan cara menghitung *error jarak* dari perkiraan posisi (x,y) dan rata-rata *error jarak* pada proses pembelajaran dengan menggunakan persamaan (6) dan persamaan (7) yang diadopsi dari penghitungan jarak vektor. Standar deviasi digunakan untuk mengetahui rentang rata-rata nilai data *error jarak* terhadap nilai data *error jarak* pada persamaan (8) [4].

$$ErrorJarak_i = \sqrt{(p_x - a_x)^2 + (p_y - a_y)^2} \quad (6)$$

$$RataRataErrorJarak = \frac{1}{N} \sum_{x=1}^N ErrorJarak_i \quad (7)$$

dengan p adalah prediksi lokasi dan a adalah lokasi aktual (lokasi target sebenarnya)

$$\sigma_x = \frac{1}{N-1} \left\{ \sum_{i=1}^N x_i^2 - \frac{1}{N} \left[\sum_{i=1}^N x_i \right]^2 \right\} \quad (8)$$

x_i merupakan *error jarak estimasi* (*error jarak*) yang terdiri dari $x_1, x_2, x_3, \dots, x_N$ serta N adalah banyaknya jumlah data *error jarak estimasi*.

G. Cross-Validation

K-fold cross validation merupakan cara untuk menemukan parameter terbaik dari satu model dengan cara menguji besarnya *error* pada data *test*. Dalam *k-fold cross validation* dataset X akan diambil secara random kedalam ukuran K bagian, X_i , $i=1, \dots, K$. Dengan menggunakan *k-fold cross validation* akan dilakukan percobaan sebanyak k buah. Tiap percobaan akan menggunakan satu buah data *testing* dan $k-1$ bagian menjadi data *training*, dan kemudian data *testing* tersebut akan ditukar dengan satu buah data *training* sehingga untuk tiap percobaan akan didapatkan data *testing* yang berbeda-beda [11].

H. Pengukuran Performance Klasifikasi

Ketika melakukan pengukuran *performance* klasifikasi terhadap masing-masing algoritma *machine learning* yang digunakan, ada beberapa ukuran dalam melihat *performance* klasifikasi tersebut, antara lain [5].

1. Error

Merupakan jumlah kesalahan yang diperoleh dari jumlah *false positive* (fp) dan *false negative* (fn) yang dibagi terhadap total data positif (p) dan data *negative* (n) atau $error = (fp+fn)/N$

2. Accuracy

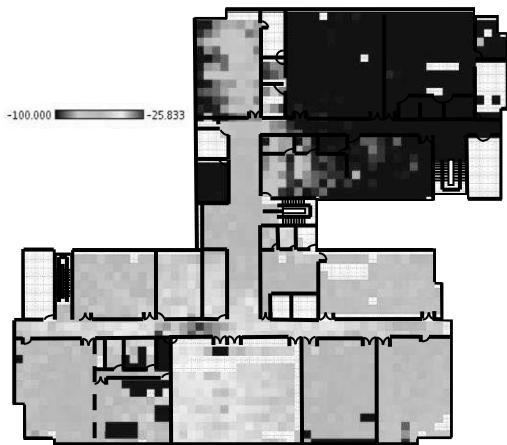
Accuracy menunjukkan kedekatan antara nilai prediksi dengan nilai aktual (*real*). *Accuracy* dihitung dengan persamaan $(tp + tn) / N$, dengan *tp* sebagai *true positive* dan *tn* adalah *true negative*.

True positive menyatakan jumlah *sample positive* yang memiliki *prediction positive*. *False positive* menyatakan jumlah *sample positive* yang memiliki *prediction negative*. *True negative* merupakan *sample negative* yang memiliki *prediction negative*, dan *false positive* merupakan *sample negative* yang memiliki *prediction positive*

III. HASIL PENELITIAN

A. Fase Offline dan Tahap Learning

Gedung JTETI lantai 3 memiliki luas bangunan $1969,68 \text{ m}^2$. Terbentuk *grid* sebanyak 1893 buah dengan jumlah data 86.980 record. Gambar 5 sampai dengan Gambar 9 merupakan gambar visualisasi peta *fingerprint* pada seluruh lantai 3 gedung JTETI.

Gambar 5. Visualisasi peta *fingerprint* pada AP-1Gambar 6. Visualisasi peta *fingerprint* pada AP-2Gambar 7. Visualisasi peta *fingerprint* pada AP-3Gambar 8. Visualisasi peta *fingerprint* pada AP-4Gambar 9. Visualisasi peta *fingerprint* pada AP-5

Tahap *training* dan *testing RSS fingerprint* (tahap *learning*) menggunakan *software* RapidMiner 5.0. Tahap *learning* menggunakan data *fingerprint* untuk data *training* sebesar 80% yang berjumlah 53120 data dan data *testing* sebesar 20% yang berjumlah 12312 data.

Tabel 1. Hasil *learning localization* lantai 3 pada tahap *off-line*

Hasil	Naive Bayes
Akurasi (meter)	6,29
Standar Deviasi error jarak (meter)	8,29

B. Fase Online dan Tahap Post Learning

Pada fase *online*, dilakukan pengujian terhadap nilai *RSS* yang diukur secara *real time* dengan cara berjalan pada koridor di lantai 3 dan memasuki ruang Lab Jaringan Komputer gedung JTETI UGM. Proses pengukuran dan pola jalan dapat dilihat pada gambar 10 dengan jumlah lokasi target sebesar 328 titik lokasi.

IV. PENUTUP

A. Kesimpulan

Berdasarkan penelitian yang telah dilakukan dapat diambil kesimpulan sebagai berikut.

1. Pada fase off line nilai rata-rata *error* jarak estimasi yang diterapkan pada *localization* untuk seluruh ruangan di lantai 3 gedung JTETI menggunakan algoritma *Naive Bayes* sebesar 6,29 meter.
2. Pada fase *online* diperoleh rata-rata *error* jarak estimasi dengan menggunakan algoritma Naive Bayes sebesar 7,82 meter

B. Saran

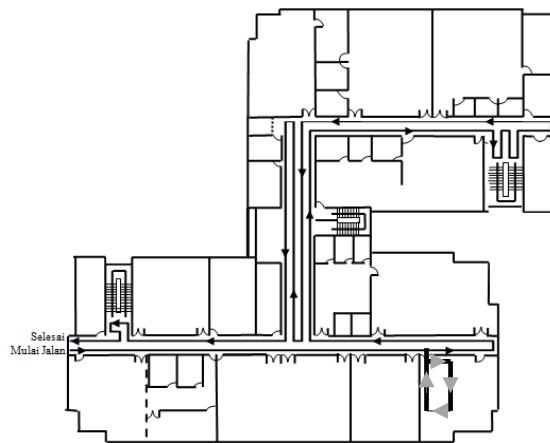
Berdasarkan hasil penelitian yang telah dilakukan, ada beberapa saran dalam proses pengembangan penelitian untuk meningkatkan akurasi estimasi posisi, antara lain.

1. Pembuatan peta *RSS fingerprint* dapat dikembangkan dengan menambahkan arah posisi pengukuran yaitu selatan, barat, dan timur.
2. Pembuatan peta *RSS fingerprint* dapat juga dikembangkan dengan memperkecil dimensi *grid* menjadi 0,5 meter.
3. *Localization* dapat dikembangkan dengan mempertimbangkan efek *multipath* dan propagasi gelombang.
4. Dapat dikembangkan penggunaan metode *Principal Component Analysis* (PCA) untuk memilih *access point* yang paling berpengaruh terhadap estimasi lokasi.
5. *Localization* dapat menggunakan algoritma lain untuk mengetahui nilai *error* yang lebih kecil.

Dimasa datang akan dilakukan *localization* pada seluruh lantai 3 gedung JTETI UGM dengan menggunakan algoritma penentuan posisi yang lain untuk mendapatkan nilai akurasi yang lebih besar dan rata-rata kesalahan jarak/*error distance* yang lebih kecil.

DAFTAR PUSTAKA

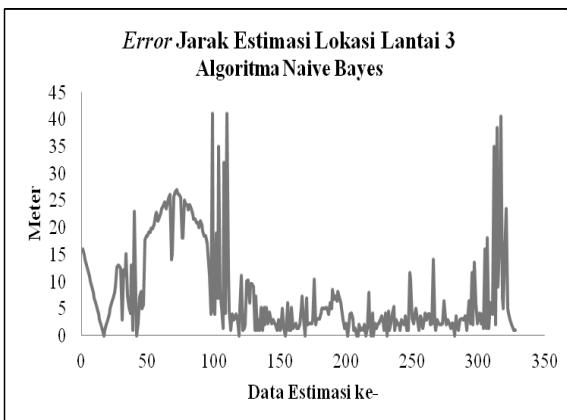
- [1] Ahmed, U., Gavrilov, A., Lee, S., and Lee, Y. K., 2007, "A Rapid Development Approach For Signal Strength Based Location System", International Conference On Intelligent Pervasive Computing, 0-7695-3006-0/07 IEEE, DOI 10.1109/IPC.2007.62.
- [2] Bensky, A., 2008, "Wireless Positioning: Technologies and Application, ser. GNSS technology and application series", Artech House Publishers.
- [3] Chen, L. H., Jin, M. H., and Wu, E. H., 2010, "A Novel RSS-Based Indoor Positioning Algoritm Using Mobility Prediction", IEEE, International Conference on Parallel Processing Workshops.
- [4] Derr, K., Manic, and M., 2008, "Wireless Indoor Location Estimation Based on Neural Network RSS Signature Recognition (LENSR)", IEEE Conference on Industrial Electronics and Applications.



Gambar 10. Pola jalan pengukuran RSS secara *real time* pada fase *online*

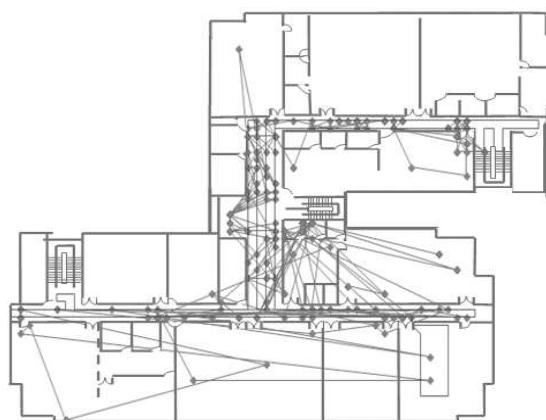
Tabel 2. Rata-rata *error* jarak estimasi dan standar deviasi pada *localization* lantai 3 pada tahap *post learning*

Keterangan	Naive Bayes (m)
Rata-Rata <i>error</i> jarak Estimasi	7,82
Standar Deviasi	8,50



Gambar 11. *Error* Jarak Estimasi Lokasi Lantai 3 Menggunakan Algoritma *Naive Bayes* pada tahap *post learning*

Gambar 12 merupakan *trajectory* estimasi lokasi pada masing-masing algoritma di lantai 3.



Gambar 12. *Trajectory* estimasi lokasi target terhadap lokasi sebenarnya dengan algoritma *Naive Bayes*.

- [5] Ethem, A., 2010, "Introduction To Machine learning", Second Edition, The MIT Press, Cambridge, Massachusetts, London, England.
- [6] Fang, S. H., Lin, T. N., and Lee., K. C., 2008, "A novel algorithm for *multipath Fingerprinting* in indoor WLAN environment", IEEE Transactions On Wireless Communications, Vol. 7, No. 9, pp. 3579-3588.
- [7] Garcia, M., Martinez, C., Tomas, J., and Lloret, J., 2007, "Wireless Sensors self-location in an Indoor WLAN environment", International Conference on Sensor Technologies and Applications, 0-7695-2988-7/07 IEEE, DOI 10.1109/SENSORCO MM.2007.63.
- [8] Kaemarungsi, K., 2005, "Design Of Indoor Positioning Systems, Based On Location *Fingerprinting* Technique", Disertasi.
- [9] Kaemarungsi, K., 2005, "Efficient Design of Indoor Positioning Systems Based on Location *Fingerprint*", IEEE.
- [10] Liu, H., Darabi, H., Banerjee, P., and Liu, J., 2007, "Survey of Wireless Indoor Positioning Techniques and Systems", IEEE Transactions On Systems, Man, And Cybernetics—Part C: Applications And Reviews, Vol. 37, No. 6, November.
- [11] Pan, S. J., Zeng, V. W., Yang, Q., and Hu, D. H., 2008, "Transfer *Learning* for WiFi-based Indoor Localization", Association for the Advancement of Artificial Intelligence.
- [12] Tran, D. A., 2009, chapter in book "Machine Learning Based *Localization*" (eds: Guoqiang mao and Baris Fidan, IGI Global).
- [13] Widyawan, 2009, "Learning Data Fusion for Indoor Localization", Department of Electronic Engineering Cork Institute of Technology, A thesis submitted for the degree of Doctor of Philosophy.
- [14] Yeung, W. M. and Joseph, K. Ng. 2007, "Wireless Lan Positioning Based On Received Signal Strength From Mobile Device And Access Points", 13th IEEE International Conference on Embedded and Real-Time Computing Systems and Applications (RTCSA 2007), 0-7695-2975-5/07.
- [15] Zhou, J., Young, W. M., and Kee-Yin Ng, J., 2008, "Enhancing Indoor Positioning Accuracy By Utilizing Signals From Both The Mobile Phone Network And The Wireless Local Area Network", 22nd International Conference on Advanced Information Networking and Applications, IEEE.