

Prediksi Tingkat Keberhasilan Studi Kinerja Santri Menggunakan Algoritma C 5.0

Achmad Agus Athok Miftachuddin.*, Kusri*, Emha Taufiq Luthfi*

Magister Teknik Informatika, Universitas Amikom Yogyakarta

Correspondence Author: agusathok7@gmail.com

Info Artikel :	ABSTRACT
Sejarah Artikel : Menerima : Revisi : Diterima : Online : Keyword : students performance, data mining, prediction, C 5.0 algorithm	<p><i>The success of pesantren education institutions can be measured by the success of their students. By predicting the possible outcomes of the learning process based on prediction results can help an Islamic boarding school, by adjusting the factors that contribute and influence the success rate of students' performance studies. And by utilizing data mining techniques that can be used to increase the level of success and reduce the failure of students. this can greatly help pesantren educational institutions to improve their graduates 'skills, because data mining is the best solution to find hidden patterns and can predict the success of students' performance studies. This research presents a model based on decision tree classification algorithm C 5.0 used in this model with alumni tracer study filled by santri alumni. In this study also used the k-folds cross validation test scenario with k values of 2,3,6,10 and 15 with a total of 300 alumni data and 84 data used for validation tests without cross validation. Determination of the criteria for the classification results using a confusion matrix form the measurement of the classification results obtained, namely the highest value in this study is 95% resulting from 15 folds the scenario 1. And form the results of testing the validation data without cross validation, the corresponding results are 73.81%, when compared to the k-folds, there was an increase of 21.19% and it can be ignored that the C 5.0 algorithm is able to classify well. So that pesantren educational institutional can provide a foundation in the arrangement for their students in deciding the right school choice.</i></p>
	INTISARI
Kata Kunci : kinerja santri, data mining , prediksi, algoritma C 5.0	<p><i>Keberhasilan lembaga pendidikan pesantren dapat diukur dari keberhasilan santrinya. Dengan memprediksi kemungkinan hasil dari proses pembelajaran berdasarkan hasil prediksi dapat membantu suatu lembaga pendidikan pesantren, dengan menyesuaikan faktor-faktor yang berkontribusi dan mempengaruhi tingkat keberhasilan studi kinerja santri. Dan dengan memanfaatkan teknik data mining yang dapat digunakan untuk meningkatkan tingkat keberhasilan dan mengurangi kegagalan santri. hal ini dapat sangat membantu lembaga pendidikan pesantren untuk meningkatkan kecakapan lulusannya, karena data mining merupakan solusi terbaik untuk menemukan</i></p>

	<p><i>pola tersembunyi dan dapat memprediksi tingkat keberhasilan studi kinerja santri. Penelitian ini menyajikan model berdasarkan pohon keputusan klasifikasi algoritma C 5.0 yang digunakan dalam model ini dengan tracer study online yang diisi oleh alumni santri. Pada penelitian ini juga menggunakan skenario uji k-folds cross validation dengan nilai k yaitu 2, 3, 6, 10 dan 15 dengan total 300 data alumni dan 84 data digunakan untuk uji validasi tanpa cross validation. Penentuan kriteria pada hasil klasifikasi menggunakan confusion matrix dari pengukuran hasil klasifikasi di peroleh hasil yaitu nilai akurasi tertinggi pada penelitian ini adalah 95% yang dihasilkan dari 15 folds skenario 1. Dan dari hasil pengujian data validasi tanpa cross validation diperoleh hasil akurasi sebesar 73,81%, jika dibandingkan dengan k-folds maka terjadi peningkatan sebesar 21,19% dan dapat disimpulkan bahwa algoritma C 5.0 mampu melakukan pengklasifikasian dengan baik. sehingga lembaga pendidikan pesantren dapat menjadikan landasan dalam pengaturan bagi santrinya dalam memutuskan pilihan sekolah yang tepat.</i></p>
--	-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

1. PENDAHULUAN

Pesantren merupakan sebuah pendidikan tradisional yang para santrinya tinggal bersama dan belajar dibawah bimbingan guru yang lebih dikenal dengan sebutan kiai dan mempunyai asrama untuk tempat menginap santri. Santri tersebut berada dalam komplek yang juga menyediakan masjid untuk beribadah, ruang untuk belajar, dan kegiatan keagamaan lainnya. Komplek ini biasanya dikelilingi oleh tembok untuk dapat mengawasi keluar masuknya para santri sesuai dengan peraturan yang berlaku (Dhofier, 1994).

Secara etimologi, istilah pondok pesantren berasal dari kata funduk (bahasa arab), dan santri yang diberi imbuhan per dan an. Kata funduk berarti ruang tidur atau wisma sederhana. Sedangkan kata pesantren berarti tempat para santri. Kata “santri” juga diartikan sebagai penggabungan antara suku kata sant (manusia baik) dan tra (suka menolong) sehingga kata pesantren dapat diartikan sebagai tempat mendidik manusia.

Di pesantren selain untuk mempelajari ilmu agama islam lebih mendalam para santri juga diwajibkan mengikuti pendidikan formal yaitu sekolah yang merupakan lembaga pendidikan yang memiliki tanggung jawab untuk memberi pengetahuan, keterampilan dan mengembangkannya dalam bentuk kegiatan sekolah. Sekolah dan nyantri adalah solusi untuk memperoleh keseimbangan ilmu pengetahuan.

Permasalahan yang dihadapi para santri baru yang berasal dari jauh adalah terdapat banyaknya pilihan sekolah yang dapat membingungkan para santri dalam menentukan sekolah yang sesuai sehingga santri mengalami kesulitan untuk mendapatkan data dan informasi secara lengkap. karena itu santri baru harus benar-benar mempertimbangkan dalam menentukan sekolah yang sesuai sebelum mengambil keputusan.

Karena itu sekolah mempunyai peranan penting dalam meningkatkan kecakapan lulusan dan menyiapkan lulusan untuk memasuki lapangan kerja dan mengembangkan sikap profesional, menyiapkan lulusan agar memilih karir, mampu berkompetisi dan mampu mengembangkan diri, menyiapkan lulusan agar menjadi warga negara yang produktif, adaptif dan kreatif. Maka lembaga pendidikan khususnya sekolah memiliki tanggung jawab yang sangat relevan terhadap pembentukan jiwa entrepreneurship bagi lulusannya (Wahyuni and Hidayati, 2017).

Berdasarkan permasalahan diatas dengan menggunakan teknik data mining dengan algoritma C 5.0 dan diimplementasikan ke suatu bahasa Pemrograman R yang diharapkan dapat memprediksi keakuratan analisa keberhasilan studi santri. dengan memantau hasil belajar santri. Yang didapatkan dari hasil tracer study alumni pondok pesantren beserta riwayat akademik terdahulu selama dibangku sekolah menengah atas yang akan diproses untuk mendapatkan pola

rule yang akan menjadi landasan dalam melakukan prediksi tingkat keberhasilan studi kinerja santri.

Algoritma C 5.0 sendiri merupakan salah satu solusi pemecahan kasus yang sering digunakan pada teknik klasifikasi. Keluaran dari algoritma C 5.0 adalah berupa tree dan rule based model. Algoritma ini adalah pengembangan dari algoritma C 4.5 dan IDE (Iterative Dichotomiser 3) algoritma C 5.0 memiliki fitur yang lebih lengkap, lebih cepat, lebih efisien dan menghasilkan tree yang lebih sederhana dari C 4.5 (Kumar Mandal, 2017). Dengan masing-masing rangkaian pembagian, anggota himpunan hasil menjadi mirip satu dengan yang lain (Berry and Linoff, 2004). Dalam algoritma C 5.0 pemilihan atribut dilakukan dengan menggunakan information gain, gain ratio dengan mencari nilai entropy. Algoritma C 5.0 mirip dengan pembangunan algoritma C4.5 kemiripan tersebut meliputi perhitungan kemunculan kejadian, perhitungan entropy dan information gain. Jika pada algoritma C 4.5 berhenti sampai perhitungan information gain, maka pada algoritma C 5.0 akan melanjutkannya dengan perhitungan gain ratio dengan menggunakan information gain dan entropy yang telah ada. Serta algoritma C 5.0 memiliki fitur yang lebih lengkap, lebih cepat, lebih efisien dan menghasilkan tree yang lebih sederhana dari C 4.5. dan membagi data berdasarkan kriteria yang dipilih untuk membuat sebuah Decision Tree dengan menggunakan pendekatan secara top-down (Wei and You, 2011).

Berdasarkan analisis yang dilakukan Johan Jansson dalam penelitiannya, algoritma C 5.0 mampu memberikan hasil yang efektif dalam mendukung suatu keputusan dengan kriteria yang dibuat secara random. Selain itu, alasan memilih menggunakan algoritma C 5.0 adalah mampu menghasilkan sub sistem model base yang dapat digunakan untuk menunjang sistem pendukung keputusan (Al-Hegami, 2007).

Maka berdasarkan uraian diatas dapat diambil judul Prediksi Tingkat Keberhasilan Studi Kinerja Santri Menggunakan Algoritma C 5.0 dan dari hasil penelitian ini adalah untuk mengetahui tingkat keberhasilan studi santri berdasarkan beberapa kriteria.

2. METODE PENELITIAN

2.1 Desain Penelitian

Desain dari penelitian ini menggunakan data primer (tracer study online) menggunakan google form sebagai alat untuk memberikan form atau soal pertanyaan secara online yang akan diinformasikan oleh pengasuh pondok pesantren kepada para responden. Responden dalam penelitian ini adalah alumni pondok pesantren di wilayah kecamatan jombang. Kuesioner yang di gunakan terlebih dahulu dilakukan uji validitas dan reliabilitas. Responden akan mengisi kuesioner berdasarkan atribut yang didapatkan dari literatur maupun wawancara dengan pengasuh pondok pesantren. Kemudian data responden akan diolah dengan aplikasi Rstudio menggunakan metode decision tree untuk mengimplementasikan algoritma C 5.0 pada program data mining. Metode penelitian yang digunakan dalam penerapan algoritma C 5.0 dalam memprediksi tingkat keberhasilan studi kinerja santri menggunakan metode CRISP-DM.

2.2 Prediksi

Digunakan untuk memperkirakan atau forecasting suatu kejadian sebelum kejadian – kejadian atau peristiwa tertentu terjadi. Misalnya pada bidang klimatologi dan geofisika yaitu bagaimana badan meterologi dan geofisika (BMKG) memperkirakan tanggal tertentu bagaimana cuacanya apakah hujan, panas dan lain sebagainya. Metode yang sering digunakan salah satunya adalah Roug set. Data mining juga sama halnya dengan konsep neural network mengandung 2 (dua) pengelompokan yaitu :

- Supervised learning merupakan pembelajaran menggunakan guru dan biasanya ditandai dengan adanya class/label/target pada himpunan data. Adapun metode-metode yang digunakan bersifat Supervised learning seperti metode prediksi dan klasifikasi algoritma C 5.0, metode roug set dan lain-lain.
- Unsupervised learning merupakan pembelajaran tanpa menggunakan guru dan biasanya ditandai pada himpunan datanya dan tidak memiliki atribut keputusan atau class/label/target. Metode-metode yang bersifat unsupervised learning meliputi metode estimasi, clustering, asosiasi, regresi linier, analytical hierarchy clustering dan lain-lain.

2.3 Algoritma C 5.0

Algoritma C 5.0 merupakan algoritma turunan dari algoritma pohon keputusan yang sebelumnya adalah algoritma C 4.5 dan sering digunakan untuk pengaplikasian data mining. Algoritma C 5.0 memiliki peningkatan dalam hal kecepatan memori sebesar 90% dari algoritma sebelumnya yaitu C 4.5 (Wirdhaningsih et al., 2013). Dan biasanya algoritma C 5.0 ini menggunakan memori lebih rendah pada algoritma C 4.5 seperti contohnya pada saat rule set pada dataset forest, dimana algoritma C 4.5 menggunakan kurang lebih 3GB memori sedangkan algoritma C 5.0 kurang lebih menggunakan 200MB memori. Dari segi akurasi, algoritma C 5.0 ini memiliki tingkat kesalahan yang rendah. Algoritma C 5.0 juga menghasilkan pohon keputusan yang lebih kecil dan juga rule set yang sedikit. Tidak seperti pada algoritma C 4.5. oleh karena itu dengan menggunakan algoritma C 5.0 memungkinkan untuk menghapus atribut yang tidak memiliki keterkaitan dengan topik penelitian secara lebih baik.

Algoritma C 5.0 menghasilkan tingkat keakuratan yang lebih tinggi dalam hal prediksi penggunaan algoritma C 5.0 dapat menghasilkan model prediksi dengan hasil tingkat akurasi yang lebih tinggi (Hutabarat, 2018). Algoritma C 5.0 diharapkan proses penggalian informasi lebih cepat dan optimal dengan kapasitas data yang lebih besar, sehingga kesalahan yang ditimbulkan dalam pengambilan keputusan lebih diminimalkan (Manik, Pristiwanto and Tampubolon, 2018).

Pada algoritma C 5.0 dapat menangani atribut kontinyu dan diskrit. Pertama yang dilakukan adalah menghitung nilai entropy dari keseluruhan atribut, lalu selanjutnya yaitu menghitung nilai information gain tertinggi dari seluruh atribut sehingga didapatkan atribut yang akan digunakan sebagai akar atau parent. Selanjutnya percabangan pada akar untuk setiap nilainya ditentukan, kemudian setiap cabang berisi kasus yang telah dibagi. Kemudian perhitungan secara berulang dilakukan untuk menentukan nilai gain. perhitungan tersebut berhenti ketika semua data telah dihitung memiliki persamaan pada kelasnya. Berikut tahapan perhitungan entropy dan gain dalam pembentukan pohon keputusan algoritma C 5.0.

Berikut persamaan untuk mencari nilai entropy sebelum dilakukannya perhitungan dalam mencari information gain :

$$\text{Entropy} = \sum_{i=1}^n (1-p_i) \cdot \log_2(1-p_i) + \sum_{i=1}^n p_i \cdot \log_2(p_i) \quad (1)$$

Keterangan :

- S : Himpunan Kasus
- n : Jumlah Partisi S
- Pi : Properti dari Si terhadap S

Sementara untuk menentukan nilai Information gain. Kemudian setelah information gain didapat tentukanlah information gain yang memiliki nilai tertinggi. Itulah yang akan menjadi akar atau parent pada istilah pohon keputusan. Dapat dilihat pada persamaan berikut

$$\text{Gain}(S,A) = \text{Entropy}(S) - \sum_{i=1}^n \left(\frac{|S_i|}{|S|} \cdot \text{Entropy}(S_i) \right) \quad (2)$$

Keterangan :

- S : Himpunan Kasus
- A : Fitur
- n : Properti Si Terhadap S
- |Si| : Proporsi Si terhadap S
- |S| : Jumlah Kasus Dalam S

Perhitungan gain ratio untuk algoritma C 5.0 akan berjalan setelah perhitungan information gain diatas dilakukan. Perhitungan gain ratio selanjutnya menggunakan persamaan dibawah ini:

$$\text{Gain Ratio} = \frac{\text{Information gain}(S,A)}{\sum_{i=1}^n \left(\frac{|S_i|}{|S|} \cdot \text{Entropy}(S_i) \right)} \quad (3)$$

Dengan adanya perhitungan gain ratio inilah yang menjadikan pembangunan tree pada C 5.0 lebih ringkas dibanding tree pada algoritma C 4.5. sehingga menyebabkan pola tingkat keberhasilan yang dihasilkan lebih sedikit dibandingkan algoritma C 4.5.

2.4 Bahasa Pemrograman R

R (Ihaka and Gentleman, 1996) adalah implementasi open source S yang bebas, dikembangkan secara kooperatif, sebuah bahasa pemrograman statistik yang kuat dan fleksibel dan lingkungan komputasi yang telah menjadi efektif pada standar di antara para ahli statistik. Meskipun memiliki poin kuat, dan basis pengguna yang besar di antara para ahli statistik (Fox and Andersen, 2005). R menyediakan berbagai teknik statistika (permodelan linier dan nonlinier, uji statistik klasik, analisis deret waktu, klasifikasi, klusterisasi, dan sebagainya) serta grafik. R, sebagaimana S, dirancang sebagai bahasa komputer sebenarnya, dan mengizinkan penggunaannya untuk menambah fungsi tambahan dengan mendefinisikan fungsi baru. Kekuatan besar dari R yang lain adalah fasilitas grafiknya, yang menghasilkan grafik dengan kualitas publikasi yang dapat memuat simbol matematika. R memiliki format dokumentasi seperti LaTeX, yang digunakan untuk menyediakan dokumentasi yang lengkap, baik secara daring (dalam berbagai format) maupun secara cetakan.

R memiliki ciri khas pada bagian syntaxnya yaitu selalu diawali dengan ">" dan bahasa R juga memiliki beberapa keunggulan diantaranya yaitu

R unggul dalam segi pengelolaan data dan juga media penyimpanannya, R memiliki kelebihan lainnya yaitu, ukuran file yang telah disimpan oleh R memiliki ukuran file yang kecil.

R memiliki layanan dalam mengoperasikan perhitungan array yang lengkap

R juga menunjang dalam hal penelitian dibidang statistik contohnya adalah menguji statistik, menguji fungsi dalam probabilitas dan sebagainya

Perangkat lunak R menyediakan tampilan grafik yang menarik bagi user dan juga fleksibel R diciptakan dengan fungsi yaitu multiplatform, yang mana multiplatform tersebut memiliki arti yaitu R dapat menyesuaikan diberbagai sistem Operasi, tidak hanya satu jenis sistem operasi saja.

3. HASIL DAN ANALISA

Dalam penelitian ini menggunakan pendekatan kualitatif. Tempat penelitian adalah pondok pesantren di Wilayah Kecamatan Jombang. Waktu penelitian dan pengambilan data pada bulan Februari sampai September 2020. Target penelitian adalah alumni santri pondok pesantren sejumlah 300 alumni dari masing-masing pondok pesantren yang berbeda di wilayah kecamatan jombang. Untuk memprediksi tingkat keberhasilan studi kinerja santri ini ditujukan pada santri yang sudah menempuh pendidikan sekolah menengah atas. Dengan demikian mereka dapat di prediksi tingkat keberhasilannya dengan menghitung jumlah class untuk hasil BERHASIL dan TIDAK BERHASIL.

3.1 Analisa hasil dan penarikan kesimpulan

Pada tahap analisa hasil dilakukan analisa terhadap faktor-faktor yang mempengaruhi tingkat keberhasilan studi kinerja santri untuk ditarik kesimpulan dari penelitian yang dilakukan.

3.2 Hasil penelitian dan pembahasan

Penelitian ini dibuat untuk memprediksi faktor-faktor yang mempengaruhi tingkat keberhasilan studi kinerja santri dengan menerapkan algoritma C 5.0 dan k-folds cross validation serta untuk uji validasi tanpa cross validation menggunakan 84 Data. Hasil akhir dari penelitian ini adalah berupa model klasifikasi yang menerangkan faktor-faktor utama yang mempengaruhi dan metode k-folds cross validation yang menerangkan untuk melakukan evaluasi klasifikasi dengan teknik cross validation, perlu diperhatikan beberapa langkah sebagai berikut :

- Melakukan perulangan sebanyak jumlah fold. Selama perulangan tersebut dilakukan pengambilan data secara random sebagai data training sebanyak dari pembagian antar jumlah total data dan jumlah fold.
- Lakukan klasifikasi pada data training dengan algoritma C 5.0
- Lakukan pengambilan data sebanyak dari jumlah sisa pembagian data training secara random sebagai data validasi, kemudian mengevaluasi model klasifikasi yang telah dilakukan sebelumnya terhadap data validasi yang ada

- Dapatkan statistik hasil kinerja evaluasi model pengklasifikasian pada data berupa TP, TN, FP dan FN.

Dalam pengujian ini, penulis menggunakan 2 fold, 3 fold, 6 fold, 10 fold, dan 15 fold. Selanjutnya setelah data dikelompokkan menjadi beberapa kelompok sesuai nilai fold, maka langkah selanjutnya menghitung tingkat akurasi dataset tracerstudy alumni pondok pesantren.

3.3 Data Preprocessing

Dalam penelitian ini dilakukan 2 teknik preprocessing, yaitu seleksi data dan transformasi data. Seleksi data dilakukan secara manual dengan kriteria atribut yang dipilih meliputi hal-hal yang bersifat akademis dan erat hubungannya dengan tingkat keberhasilan studi kinerja santri. Transformasi data dilakukan untuk memperbaiki data-data yang bernilai terlalu panjang dengan menyederhanakan nilai atribut sehingga memudahkan nantinya dalam pembuatan model decision tree algoritma C 5.0 pada Rstudio

3.4 Implementasi Algoritma C 5.0

Implementasi algoritma C 5.0 dilakukan dengan bantuan perangkat lunak Rstudio dan menggunakan bahasa pemrograman R. Pembuatan model C 5.0 untuk menghasilkan nilai akurasi menggunakan Uji K fold cross validation dengan $k = 2, 3, 6, 10$ dan 15 seperti yang di tunjukkan pada gambar 1 berikut

```

~/ >
> # Apply Cross Folds validation
> folds <- cut(seq(1,nrow(santri)),breaks=2, labels=FALSE)
> for(i in 1:1){
+   TestIndexes <- which(folds==i, arr.ind = TRUE)
+   testData <- santri[TestIndexes, ]
+   trainData <- santri[-TestIndexes, ]
> treeC5 = c5.0 (x = trainData[, -7], y=trainData$Tingkat_Keberhasilan)
> prediktor = predict(treeC5, testData[, -7])
> confusionMatrix(prediktor,testData$Tingkat_Keberhasilan, mode = "prec_recall")
Confusion Matrix and Statistics

          Reference
Prediction  Berhasil Tidak Berhasil
Berhasil      83          5
Tidak Berhasil 30         32

      Accuracy : 0.7667
      95% CI   : (0.6907, 0.8318)
No Information Rate : 0.7533
P-value [Acc > NIR] : 0.3939

      Kappa : 0.4884

McNemar's Test P-value : 4.976e-05

      Precision : 0.9432
      Recall : 0.7345
      F1 : 0.8259
      Prevalence : 0.7533
      Detection Rate : 0.5533
      Detection Prevalence : 0.5867
      Balanced Accuracy : 0.7997

      'Positive' class : Berhasil

> summary(prediktor)
      Berhasil Tidak Berhasil
      88          62
  
```

Gambar 1. Source Code K fold Cross Validation Uji Akurasi, Presisi dan Recall

Source code pada gambar 1. diulang sebanyak jumlah fold dengan menggunakan data santri. Hasilnya pada skenario uji K 2.1 memiliki nilai presisi 94,32% dan nilai recall 73,45% dan nilai TP : 83, TN : 32, FP: 5 , FN: 30, Adapun hasil keseluruhan Uji K2.1 – Uji K15.15 dapat dilihat pada tabel 1. Berikut :

Tabel 1. Hasil Pengukuran Akurasi, Presisi dan Recall

No	Uji Ke	TP	TN	FP	FN	Berhasil	Tidak Berhasil	Akurasi	Presisi	Recall
1	K 2.1	83	32	5	30	88	62	76,67	94,32	73,45
2	K 2.2	89	19	23	19	112	38	72	79,46	82,41
3	K 3.1	67	15	9	9	76	24	82	88,16	88,16
4	K 3.2	47	21	4	28	51	49	68	92,16	62,67
5	K 3.3	63	5	25	7	88	12	68	71,59	90
6	K 6.1	36	9	4	1	40	10	90	90	97,30
7	K 6.2	27	11	0	12	27	23	76	100	69,23
8	K 6.3	20	11	2	17	22	28	62	90,91	54,05
9	K 6.4	30	6	6	8	36	14	72	83,33	78,95
10	K 6.5	26	9	7	8	33	17	70	78,79	76,47
11	K 6.6	31	11	3	5	34	16	84	91,18	86,11
12	K 10.1	23	5	1	1	24	6	93,33	95,83	95,83
13	K 10.2	19	2	8	1	27	3	70	70,37	95
14	K 10.3	17	6	0	7	17	13	76,67	100	70,83
15	K 10.4	12	7	0	11	12	18	63,33	100	52,17
16	K 10.5	12	6	2	10	14	16	60	85,71	54,55
17	K 10.6	17	5	1	7	18	12	73,33	100	53,33
18	K 10.7	15	3	7	5	22	8	60	85,71	46,15
19	K 10.8	20	2	8	0	28	2	73,33	92,31	66,67
20	K 10.9	15	7	0	8	15	15	73,33	91,67	73,33
21	K 10.10	18	4	5	3	23	7	73,33	78,26	85,71
22	K 15.1	16	3	0	1	16	4	95	100	94,12
23	K 15.2	13	5	2	0	15	5	90	86,67	100
24	K 15.3	13	1	5	1	18	2	70	72,22	92,86
25	K 15.4	12	4	0	4	12	8	80	100	75
26	K 15.5	9	4	0	7	9	11	65	100	56,25
27	K 15.6	8	5	0	7	8	12	65	100	53,33
28	K 15.7	6	6	1	7	7	13	60	85,71	46,15
29	K 15.8	12	1	1	6	13	7	65	92,31	66,67
30	K 15.9	11	4	1	4	8	12	75	91,67	73,33
31	K 15.10	13	1	5	1	18	2	70	72,22	92,86
32	K 15.11	9	2	5	4	14	6	55	64,29	69,23
33	K 15.12	13	1	6	0	19	1	70	68,42	100
34	K 15.13	8	5	0	7	8	12	65	100	53,33
35	K 15.14	14	4	0	2	14	6	90	100	87,50
36	K 15.15	12	4	3	1	15	5	80	80	92,31
Rata - rata									97,50	92

Dari tabel 1. diatas dapat diketahui bahwa nilai akurasi tertinggi diperoleh pada skenario uji K 15.1 dengan nilai 95% dan rata-rata nilai Presisi adalah bernilai 97,50% sedangkan untuk rata-rata nilai recall mencapai nilai 92%.

Setelah dilakukan pengujian pada pemrograman r menggunakan 2,3,6,10 dan 15 *fold cross validation* maka hasilnya dapat dilihat pada tabel 2. berikut :

Tabel 2. Tabel Hasil Akurasi, presisi dan recall dengan Pemrograman R

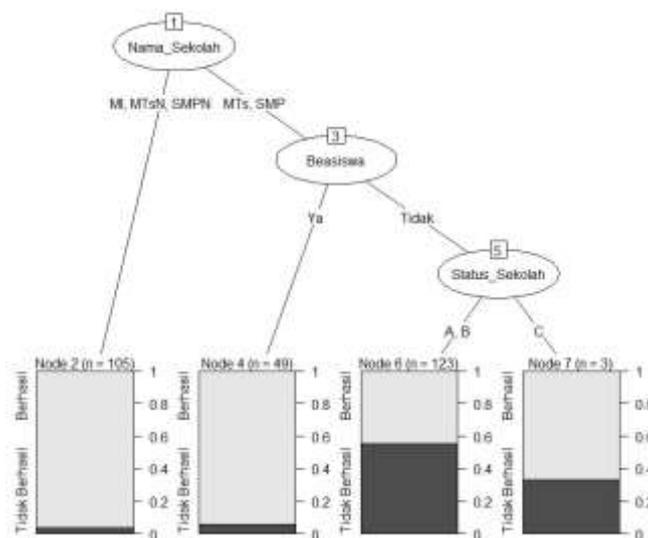
No	Fold	TP	TN	FP	FN	Berhasil	Tidak Berhasil	Hasil Akurasi	Hasil Presisi	Hasil Recall
1	2	83	32	5	30	88	62	76,67	94,32	73,45
2	3	67	15	9	9	76	24	82	88,16	88,16
3	6	36	9	4	1	40	10	90	90	97,30
4	10	23	5	1	1	24	6	93,33	95,83	95,83
5	15	16	3	0	1	16	4	95	100	94,12

Dari hasil pengujian pada bahasa pemrograman r seperti terlihat pada tabel 4.14. berikut dapat disimpulkan bahwa :

1. Jumlah *fold* mempengaruhi hasil akurasi
2. Nilai rata-rata untuk hasil akurasi sebesar 95%
3. Nilai rata-rata untuk hasil presisi sebesar 97,50%
4. Nilai rata-rata untuk hasil recall sebesar 92%
5. Pada pengujian diatas, yang memiliki hasil maksimal prosentase akurasi adalah pada pengujian *fold* bernilai 15 skenario 1, sedangkan yang memiliki hasil akurasi terendah adalah pengujian dengan menggunakan *fold* bernilai 15 skenario 11.

Setelah proses hasil uji akurasi pada subbab sebelumnya, maka di hasilkan pula suatu model klasifikasi yang terbentuk dari algoritma C 5.0 dimana model tersebut direpresentasikan sebagai struktur pohon dan memuat informasi *decision tree* dari data tracer studi alumni satri yang telah diproses oleh algoritma C 5.0, berikut hasil dari *decision tree* skenario 15, 1 folds cross validation yang terbentuk

Setelah proses hasil uji akurasi pada subbab sebelumnya, maka di hasilkan pula suatu model klasifikasi yang terbentuk dari algoritma C 5.0 dimana model tersebut direpresentasikan sebagai struktur pohon dan memuat informasi *decision tree* dari data tracer studi alumni satri yang telah diproses dengan algoritma C 5.0, berikut hasil dari *decision tree* skenario 15, 1 folds cross validation yang terbentuk.



Gambar 2. Pohon Keputusan Akhir

Dari gambar pohon keputusan diatas dapat disimpulkan bahwa nama sekolah menjadi akar utama dalam prediksi tingkat keberhasilan studi kinerja santri selanjutnya diikuti variabel beasiswa, dan yang terakhir adalah status sekolah. Dan dari model yang sudah terbentuk menunjukkan bahwa data terlihat seimbang. Artinya hasil pembelajaran dapat melakukan prediksi dengan baik untuk class berhasil dan tidak berhasil.

3.5 Aturan – Aturan / Rule Model

Dari pohon keputusan yang terbentuk pada gambar 2. Didapat aturan-aturan / rule model dalam prediksi tingkat keberhasilan studi kinerja santri. Ada 4 aturan yang terbentuk, dapat dilihat sebagai berikut

1. *If* Nama_Sekolah = MI, MTsN, SMPN *then* Tingkat Keberhasilan = Berhasil
2. *If* Nama_Sekolah = MTs, SMP *And* Beasiswa = Ya *then* Tingkat Keberhasilan = Berhasil
3. *If* Beasiswa = Tidak *And* Status Sekolah = A,B *then* Tingkat Keberhasilan = Tidak Berhasil
4. *If* Status Sekolah = C *then* Tingkat Keberhasilan = Berhasil

3.6 Tahap Analisis Hasil Pengujian

Pada penelitian ini, analisa menggunakan sebuah sistem yaitu *data mining* dengan metode *Algoritma C 5.0*. Didalam proses pengeksraksian membutuhkan data tingkat keberhasilan studi santri yang didapat dari tracer alumni santri. Berikut ini adalah data sampel yang berupa tabel yang akan dilakukan proses ekstraksi sesuai dengan langkah pada metode ini.

	Nama_Sekolah	Status_Sekolah	Jumlah_Saudara	Riwayat_Sebelum_Dipesantren	Jarak_Tempuh	Beasiswa	Tingkat_Keberhasilan
21	MTsN	A	Banyak	Dipesantren	Sedang	Tidak	Berhasil
22	MTs	B	Banyak	Bersama Orangtua	Jauh	Tidak	Tidak Berhasil
23	MTs	B	Banyak	Dipesantren	Jauh	Tidak	Tidak Berhasil
24	SMPN	A	Banyak	Bersama Orangtua	Jauh	Tidak	Berhasil
25	MTsN	A	Banyak	Dipesantren	Dekat	Tidak	Berhasil
26	SMPN	B	Banyak	Bersama Orangtua	Sangat Jauh	Tidak	Berhasil
27	SMPN	A	Banyak	Bersama Orangtua	Sangat Jauh	Tidak	Berhasil
28	SMP	B	Sedikit	Dipesantren	Sangat Jauh	Ya	Berhasil
29	MTs	B	Banyak	Bersama Orangtua	Jauh	Tidak	Tidak Berhasil
30	MTsN	A	Sedikit	Dipesantren	Sangat Jauh	Ya	Berhasil

Gambar 3. Data Training

Setelah mendapatkan data training, kemudian melakukan proses perhitungan jumlah data, entropy, information gain dan gain ratio. Hasil tersebut terdapat pada tabel 3.

Langkah selanjutnya dilakukan perhitungan entropi total, information gain beserta gain ratio dari setiap atribut untuk menentukan *node* pertama berdasarkan tabel data sebelumnya berdasarkan ketentuan dasar entropi sebagai berikut :

Tabel 3. Perhitungan Jumlah Tingkat Keberhasilan

Node	Atribut	Nilai	Sum (nilai)	Berhasil	Tidak_Berhasil
				Si	Si
1	Total		280	204	76
	Nama Sekolah				
		MI	23	20	3
		SMP	63	41	22
		SMPN	34	34	0
		MTs	112	62	50
		MTsN	48	47	1
	Beasiswa				
		Ya	78	75	3
		Tidak	202	129	73
	Status Sekolah				
		A	122	107	15
	B	154	94	60	
	C	4	3	1	

Setelah diketahui kemunculan setiap prediktor seperti yang terlihat pada tabel diatas, kemudian dicari nilai entropy. Perhitungan entropy pada Algoritma C 5.0, dengan Persamaan (1). Persamaan diatas berlaku pada semua atribut, termasuk atribut target, Tingkat Keberhasilan. Entropy pada atribut Tingkat Keberhasilan akan menjadi entropy total. Berikut perhitungan entropy dalam pemilihan root.

$$\begin{aligned} \text{Entropy (Total)} &= -(204/280) * (\log_2 (204/280)) + -(76/280) * (\log_2 (76/280)) \\ &= 0.84350708557 \end{aligned}$$

$$\begin{aligned} \text{Entropy (MI)} &= -(20/23) * (\log_2 (20/23)) + -(3/23) * (\log_2 (3/23)) \\ &= 0.55862937345 \end{aligned}$$

$$\begin{aligned} \text{Entropy (SMP)} &= -(41/63) * (\log_2 (41/63)) + -(22/63) * (\log_2 (22/63)) \\ &= 0.93335726001 \end{aligned}$$

$$\begin{aligned} \text{Entropy (SMPN)} &= -(34/34) * (\log_2 (34/34)) + -(0/34) * (\log_2 (0/34)) \\ &= \text{NaN} \end{aligned}$$

$$\begin{aligned} \text{Entropy (MTs)} &= -(62/112) * (\log_2 (62/112)) + -(50/112) * (\log_2 (50/112)) \\ &= 0.99170330837 \end{aligned}$$

$$\begin{aligned} \text{Entropy (MTsN)} &= -(47/48) * (\log_2 (47/48)) + -(1/48) * (\log_2 (1/48)) \\ &= 0.14609425012 \end{aligned}$$

$$\begin{aligned} \text{Entropy (Ya)} &= -(75/78) * (\log_2 (75/78)) + -(3/78) * (\log_2 (3/78)) \\ &= 0.23519338181 \end{aligned}$$

$$\begin{aligned} \text{Entropy (Tidak)} &= -(129/202) * (\log_2 (129/202)) + -(73/202) * (\log_2 (73/202)) \\ &= 0.94382777607 \end{aligned}$$

$$\begin{aligned} \text{Entropy (A)} &= -(107/122) * (\log_2 (107/122)) + -(15/122) * (\log_2 (15/122)) \\ &= 0.53778384183 \end{aligned}$$

$$\begin{aligned} \text{Entropy (B)} &= -(94/154) * (\log_2 (94/154)) + -(60/154) * (\log_2 (60/154)) \\ &= 0.96454765891 \end{aligned}$$

$$\begin{aligned} \text{Entropy (C)} &= -(3/4) * (\log_2 (3/4)) + -(1/4) * (\log_2 (1/4)) \\ &= 0.81127812445 \end{aligned}$$

Setelah perhitungan entropy seperti diatas, maka dilakukan perhitungan information gain. Perhitungan information gain ini menggunakan Persamaan (2). Berikut perhitungan Information Gain dalam penentuan root. Nilai pada entropy (S) yang dipakai adalah Entropy Total.

$$\begin{aligned} \text{InformationGain(Nama_Sekolah,Total)} &= 0.84350708557 - ((23/280) * 0.55862937345) \\ &+ ((63/280) * 0.93335726001) + ((43/280) * \text{NaN}) + ((112/280) * 0.99170330837) + ((48/280) * \\ &0.14609425012) \\ &= 0.165888237 \end{aligned}$$

$$\begin{aligned} \text{InformationGain(Beasiswa,Total)} &= 0.84350708557 - ((78/280) * 0.23519338181) \\ &+ ((202/280) * 0.94382777607) \\ &= 0.097084605 \end{aligned}$$

$$\begin{aligned} \text{InformationGain(Status_Sekolah,Total)} &= 0.84350708557 - ((122/280) * 0.53778384183) \\ &+ ((154/280) * 0.96454765891) + ((4/280) * 0.81127812445) = 0.067096083 \end{aligned}$$

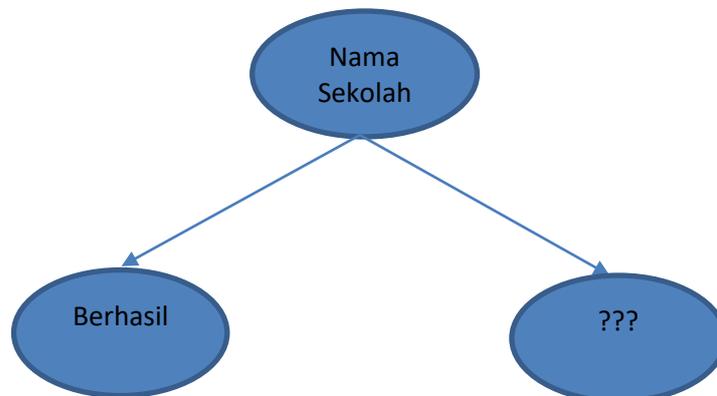
Perhitungan information gain seperti diatas yang digunakan untuk membuat node 1 (root) pada Algoritma C 5.0. Pada Algoritma C5.0, perhitungan node akan dilakukan berdasarkan perhitungan gain ratio. Untuk perhitungan ini, dapat menggunakan Persamaan (3). Berikut perhitungan Gain Ratio dalam penentuan root. Sehingga Tabel 3 diatas berubah menjadi Tabel 4 dibawah ini.

$$\begin{aligned} \text{GainRatio (Nama Sekolah)} &= 0.165888237/ 0.558629373 + 0.93335726 + 0 + \\ &\quad 0.991703308 + 0.14609425 \\ &= 0.196664901 \\ \text{GainRatio (Beasiswa)} &= 0.097084605/0.235193382+0.943827776 \\ &= 0.115096372 \\ \text{GainRatio (Status Sekolah)} &= 0.067096083/0.537783842+0.964547659+0.811278124 \\ &= 0.079544184 \end{aligned}$$

Tabel 4. Perhitungan Entropy, Informaton Gain dan gain ratio

Node	Atribut	Nilai	Sum (nilai)	Berhasil	Tidak_Berhasil	Entropy	Information Gain	Gain Ratio
				Si	Si			
	Total		279	206	73	0.843507086		
	Nama Sekolah						0.165888237	0.196664901
		MI	21	18	3	0.558629373		
		SMP	51	32	19	0.93335726		
		SMPN	32	32	0	0		
		MTs	81	47	34	0.991703308		
		MTsN	31	31	0	0.14609425		
	Beasiswa						0.097084605	0.115096372
		Ya	60	59	1	0.235193382		
		Tidak	156	101	55	0.943827776		
							0.067096083	0.079544184
	Status Sekolah							
		A	122	107	15	0.537783842		
		B	154	94	60	0.964547659		
		C	4	3	1	0.811278124		

Pada tabel diatas, nilai gain tertinggi terdapat pada Nama Sekolah dibandingkan dengan atribut lainnya terlihat gain tertinggi yaitu nama sekolah, nama sekolah menjadi sebuah akar karena memiliki gain tertinggi pertama. Perhatikan gambar berikut ini:



Gambar 4.26. Nama Sekolah Menjadi akar

Penjelasan pada gambar diatas bahwa nama sekolah, kemudian dalam nama sekolah terdapat 2 anggota yaitu MI, MTsN, SMPN dan MTs, SMP, dan kelayakan nya terdapat 2 keputusan yaitu

berhasil dan Tidak berhasil. Karena nama sekolah yang memilih MI, MTsN, SMPN datanya terdapat dinilai berhasil semua, dan tidak berhasilnya nya terdapat nilai 0. Maka kelayakan yang memilih nama sekolah MI,MTsN,SMPN adalah berhasil. Sedangkan nama sekolah yang memilih MTs & SMP ada nilai antara berhasil dan tidak berhasil, maka dibuat kembali node dan pohon keputusannya. Sehingga dari pohon diatas nama sekolah yang memilih MTs & SMP maka masih dipertanyakan.

3.7 Validasi dan Pengujian

Dari hasil klasifikasi dan pengukuran pada data validasi dengan jumlah 84 data dengan tanpa menggunakan k fold cross validation diperoleh hasil sebagai berikut :

Tabel 4.17. Confusion Matrix

	True Berhasil	True Tidak Berhasil
Pred. Berhasil	50	11
Pred. Tidak Berhasil	11	12

Hasil Confusion matrix pada tabel 4.17. Algoritma C 5.0 mampu mengidentifikasi sebanyak 84 data yang sesuai dengan data uji. Dari hasil data uji, 50 data bernilai berhasil dan 11 data bernilai tidak berhasil, sehingga didapat algoritma C 5.0 mampu mengidentifikasi berhasil sebanyak 50 data dan tidak berhasil sebanyak 11 data, kesalahan identifikasi sebanyak 23 data.

Analisis hasil pengujian dilakukan dengan melakukan perhitungan secara manual dengan confusion matrix. Perhitungan menggunakan model confusion matrix. Berikut ini merupakan hasil dari perhitungan confusion matrix pada algoritma C 5.0

$$\text{Accuracy} = ((50+12)/84)*100\% = 73,81\%$$

$$\text{Precision} = ((50/(50+11))*100\%) = 81,97\%$$

$$\text{Recall} = ((50/(50+11))*100\%) = 81,97\%$$

Dari perhitungan diatas, dapat disimpulkan bahwa hasil dari perhitungan accuracy, precision dan recall tersebut sama dengan hasil perhitungan yang ditampilkan pada tabel 4.16. berdasarkan pengujian dan analisa hasil pengujian yang dilakukan, dengan tingkat akurasi 73,81% presisi 81,97% recall 81,97% menunjukkan nilai akurasi yang masih dalam kategori baik presisi dan recall yang bernilai seimbang menyimpulkan bahwa peneliti berhasil dalam mengimplementasikan algoritma klasifikasi C 5.0 dengan baik dan akan membantu calon santri dan wali santri dalam menentukan pilihan sekolah yang tepat, apakah berhasil atau tidak.

4. KESIMPULAN

4.1 Kesimpulan

- a. Proses pengumpulan data dalam penelitian ini menggunakan metode kualitatif dimana penyebaran kuesioner dilakukan dengan mengimplementasikan google form sebagai alat untuk memberikan form atau soal pertanyaan secara online yang akan diinformasikan oleh pengasuh pondok pesantren dan diberikan kepada alumni. Dalam kuesioner peneliti menyisipkan pertanyaan yang berhubungan erat dengan riwayat akademik terdahulu dan status sosial ketika menjadi calon santri yang digunakan sebagai parameter atribut yang paling signifikan untuk merepresentasikan tingkat keberhasilan studi santri dengan menggunakan teknik data mining dan diperoleh hasil sebagai berikut variabel nama sekolah dan variabel beasiswa adalah variabel yang mempengaruhi tingkat keberhasilan studi santri sehingga pondok pesantren dapat menjadikan landasan dalam pengaturan bagi santrinya dalam memutuskan pilihan sekolah.
- b. Sedangkan dari hasil implementasi data mining dengan menggunakan algoritma C.5.0 mampu menghasilkan rule guna memprediksi tingkat keberhasilan studi santri berdasarkan riwayat akademik terdahulu dan status sosial ketika masih menjadi calon santri. Pengujian decision

system dengan menggunakan Aplikasi RStudio sangat dirasakan dapat mempermudah proses decision system dalam menghasilkan rule keputusan sebagai dasar melakukan prediksi. Dan berdasarkan hasil uji coba yang sudah dilakukan dapat diketahui bahwa dari uji validasi tanpa cross validation yaitu 73,81% jika dibandingkan dengan hasil yang di peroleh pada skema 15 fold skenario 1 yaitu 95% terjadi peningkatan 21,19%, dengan demikian yang memiliki nilai akurasi tertinggi adalah dengan menggunakan metode cross validation. Yang artinya algoritma ini mampu melakukan pengklasifikasian dengan baik.

4.2 Saran

- a. Penelitian selanjutnya agar dapat menggunakan metode klasifikasi lain untuk menemukan tingkat akurasi, presisi dan recall lebih baik.
- b. Pada penelitian ini menggunakan 300 record. Pada penelitian selanjutnya untuk mengestimasi akurasi yang digunakan pada sebuah algoritma akan lebih baik jika record yang digunakan lebih banyak sehingga kemungkinan akurasi akan lebih akurat dalam sebuah perhitungan algoritma.
- c. Penelitian ini masih menggunakan cara manual dalam mencocokkan tingkat keberhasilan kedalam klasifikasi berhasil dan tidak berhasil dengan algoritma C 5.0 yang telah dihasilkan dari Rstudio dengan data yang ada. Pada penelitian selanjutnya akan lebih baik jika dibuatkan sistem pendukung keputusan dalam menentukan sekolah yang tepat.

ACKNOWLEDGEMENTS

Terima kasih kepada Segenap Pengasuh Pondok Pesantren di Wilayah Kecamatan Jombang yang telah memberikan izin kepada peneliti untuk menyebarkan kuesioner online. Soal pertanyaan secara online ini akan diinformasikan oleh pengasuh pondok pesantren kepada para responden. Responden dalam penelitian ini adalah alumni pondok pesantren sebanyak 300 alumni. Penelitian ini ditujukan sebagai salah satu syarat kelulusan program studi magister teknik informatika pada universitas AMIKOM Yogyakarta.

DAFTAR PUSTAKA

- Al-Hegami, A. S. (2007). Classical and incremental classification in data mining process. *Int. J. Comput. Sci. Netw. Security*, 7(12), 179-187.
- Berry, M. J., & Linoff, G. S. (2004). *Data mining techniques: for marketing, sales, and customer relationship management*. John Wiley & Sons.
- Breiman, L., Friedman, J. H., Olshen, R. A., & Stone, C. J. (1984). *Classification and regression trees*. Wadsworth & Brooks. Cole Statistics/Probability Series.
- Burdukiewicz, M., Pietluch, F., Chilimoniuk, J., Sidorcuk, K., Rafacz, D., Jessen, L. E., ... & Why, R. (2019). Conference report: Why r? 2019. *R Journal*, 12(1), 484-493.
- Dhofier, Z. (1994). *Tradisi Pesantren, cet. VI*. Jakarta: LP3ES.
- Dunham, M. H., & Ming, D. (2003). *Introductory and advanced topics*.
- Fox, J., & Andersen, R. (2005). Using the R statistical computing environment to teach social statistics courses. Department of Sociology, McMaster University, 2-4.
- Han, J., Kamber, M., & Pei, J. (2011). *Data Mining: Concepts and Techniques Third Edition [M]*. The Morgan Kaufmann Series in Data Management Systems, 5(4), 83-124.
- Larose, D. T., & Larose, C. D. (2016). *Discovering knowledge in data. An introduction to data mining*. (2. ed.) Wiley 2014.
- Torgo, L. (2011). *Data mining with R: learning with case studies*. Chapman and Hall/CRC.
- Wahyuni, W. R., & Hidayati, W. (2017). Peran sekolah dalam membentuk keterampilan wirausaha berbasis tauhid di SD Entrepreneur Muslim Alif-A Piyungan Bantul Yogyakarta. *MANAGERIA: Jurnal Manajemen Pendidikan Islam*, 2(2), 359-377.
- Wei, C. C., & You, J. Y. (2011). C4. 5 classifier for solving the problem of water resources engineering. In *Proceeding Of The International Conference On Advanced Science, Engineering And Information Technology*, Isbn (pp. 978-983).