

5. PENGUJIAN SISTEM


5.1 Attribute Selection

Pada tahap awal penelitian dilakukan proses pemilihan atribut berdasarkan tingkat korelasi dengan label. Proses ini dilakukan dengan bantuan heatmap untuk memudahkan melihat korelasi. Terdapat 18 atribut yang digunakan dalam proses seleksi ini yaitu :

- a. Id Customer
- b. Jenis Perusahaan
- c. Lokasi
- d. Tahun Join
- e. Total Tahun
- f. Total Belanja
- g. Total Fasilitas
- h. Jumlah Komplain
- i. Average nilai data center
- j. Nilai data center 2 tahun terakhir
- k. Nilai data center 1 tahun terakhir
- l. Average nilai TS
- m. Nilai TS 2 tahun terakhir
- n. Nilai TS 1 tahun terakhir
- o. Average nilai AM
- p. Nilai AM 2 tahun terakhir
- q. Nilai AM 1 tahun terakhir
- r. Label

Analisa dataset juga dilakukan dengan mengecek korelasi antara jumlah komplain dan average belanja *customer* terhadap label. Pengecekan terhadap spekulasi korelasi ini dilakukan secara manual apabila nilai belanja *customer* tinggi dan jumlah komplain tinggi apakah kemungkinan besar *churn* dan apabila nilai belanja rendah dan jumlah komplain tinggi apakah pelanggan tidak *churn*. Dari data dapat dilihat bahwa *churn* atau tidaknya lebih tergantung pada jumlah komplain dari *customer*. Meskipun jumlah rupiah yang dikeluarkan rendah , namun bila komplainnya banyak maka akan tetap *churn*.

Berikut adalah hasil cek korelasi dalam bentuk heatmap.



Gambar 5.1 Nilai korelasi antar atribut


Dari nilai korelasi diatas dapat diseleksi atribut yang paling berpengaruh pada label sehingga dapat digunakan pada model prediksi nantinya. Pada heatmap sudah dibantu diurutkan dari atribut yang memiliki korelasi kuat hingga yang memiliki korelasi yang lemah terhadap atribut label. Nilai korelasi ada yang positif dan negatif, nilai positif memiliki arti bahwa atribut tersebut dan atribut label memiliki hubungan searah. Salah satu contoh atribut yang memiliki nilai positif terhadap label adalah average nilai TS, hal ini berarti semakin tinggi average nilai TS maka semakin tinggi kemungkinan customer tersebut not churn. Sebaliknya pada atribut jumlah komplain memiliki nilai korelasi negatif terhadap label yang berarti semakin tinggi jumlah komplain maka semakin rendah kemungkinan untuk tidak churn.

Tabel 5.1 Seleksi Atribut

Atribut	Nilai Korelasi Terhadap Label	Hasil
---------	-------------------------------	-------

Id Customer	0.268	Tidak Dipilih
Jenis Perusahaan	0.077	Tidak Dipilih
Lokasi	0.003	Tidak Dipilih
Tahun Join	0.259	Tidak Dipilih
Total Tahun	0.198	Tidak Dipilih
Total Belanja	0.089	Tidak Dipilih
Total Fasilitas	0.368	Tidak Dipilih
Jumlah Komplain	-0.610	Dipilih
average nilai data center	0.749	Dipilih
nilai data center 2 tahun terakhir	0.596	Tidak Dipilih
nilai data center 1 tahun terakhir	0.651	Dipilih
average nilai TS	0.702	Dipilih
nilai TS 2 tahun terakhir	0.44	Tidak Dipilih
nilai TS 1 tahun terakhir	0.734	Dipilih
average nilai AM	0.607	Dipilih
nilai AM 2 tahun terakhir	0.481	Tidak Dipilih
nilai AM 1 tahun terakhir	0.464	Tidak Dipilih

Atribut yang dipilih adalah yang memiliki nilai korelasi lebih dari 0.6 baik positif maupun negatif. Dari atribut yang dipilih akan dilakukan seleksi tahap kedua yaitu pengecekan korelasi antar atribut. Bila korelasi antar 2 atribut lebih dari 0.6 maka hanya akan dipilih salah satu. Untuk memudahkan melihat nilai korelasi heatmap dibawah ini hanya berisi atribut yang “dipilih”.



Gambar 5.2 Nilai korelasi antar atribut setelah seleksi

Dapat dilihat dari *heatmap* diatas atribut average nilai data center berkorelasi kuat dengan nilai data center 1 tahun terakhir sehingga nilai data center 1 tahun terakhir akan di drop karena memiliki nilai korelasi yang lebih rendah dengan label. Atribut nilai TS 1 tahun terakhir juga memiliki korelasi yang kuat terhadap average nilai TS sehingga atribut average nilai TS akan di drop. Dengan begitu atribut final yang akan digunakan untuk pembuatan model adalah average nilai data center, nilai TS 1 tahun terakhir, average nilai AM, dan jumlah komplain.

Untuk membuktikan bahwa seleksi atribut memberi pengaruh terhadap performa model, telah dicoba dengan model yang sama tetapi dengan data yang berbeda yaitu sebelum dan setelah seleksi atribut. Metode yang digunakan untuk testing model adalah Gaussian Naïve Bayes. Hasil confusion matrix pada data sebelum seleksi atribut adalah nilai presisi 89%, recall 100%, f1 score 94%, dan accuracy 89%. Sedangkan model dengan dataset setelah seleksi menghasilkan nilai precision 100%, recall 99%, f1 score 100%, dan accuracy 99%.

Pengecekan data berdasarkan lokasi juga dilakukan dengan membagi data menjadi Surabaya dan sekitarnya dengan Jakarta dan sekitarnya. Korelasi atribut data daerah Jakarta dan sekitarnya bila dibandingkan dengan Surabaya sekitar relatif sama bila dilihat dari atribut yang berkorelasi kuat

dengan label. Nilai korelasinya hanya selisih sedikit saja sehingga lokasi *customer* tidak mempengaruhi sifat atau atribut yang lain.

5.2 Pengujian Parameter Support Vector Machine

Dalam pembuatan model prediksi *customer churn* akan menggunakan dua metode untuk dibandingkan, salah satunya adalah metode Support Vector Machine (SVM). Pada metode SVM dapat dilakukan *hyperparameter tuning*

dengan menyesuaikan parameter - parameter yang ada agar model lebih sesuai. Parameter dari SVM adalah nilai c dengan default 1.0, kernel dengan default rbf, dan γ dengan default scale. *Hyperparameter tuning* akan difokuskan pada kernel.


5.2.1 Kernel Polynomial

Kernel pertama yang dicoba adalah polynomial. Pada kernel ini akan dicoba ketiga split data yaitu 80% training dan 20 % testing, 70% training dan 30% testing, serta 60% training dan 40% testing. Untuk mengukur akurasi 3 model tersebut akan digunakan confusion matrix. Pada model dengan data training 60% menghasilkan:

Untuk model dengan data training 80 % menghasilkan:

Tabel 5.2 Hasil confusion matrix SVM polynomial data 80%

Label	Accuracy	Precision	Recall	F-1 score
0		1	1	1
1	1	1	1	1

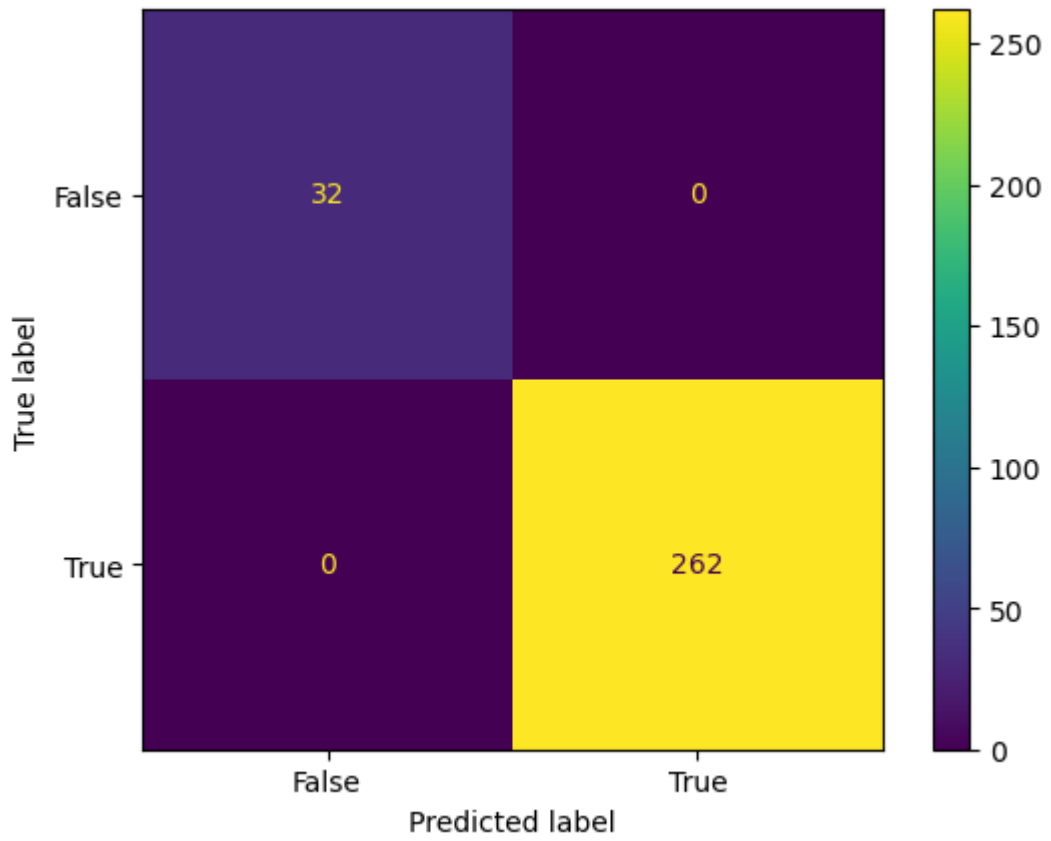


Gambar 5.3 Hasil confusion matrix SVM polynomial data 80%

Untuk model dengan data training 70 % menghasilkan:

Tabel 5.3 Hasil confusion matrix SVM polynomial data 70%


Label	Accuracy	Precision	Recall	F-1 score
0		1	1	1
1	1	1	1	1



Gambar 5.4 Hasil confusion matrix SVM polynomial data 70%

Tabel 5.4 Hasil confusion matrix SVM polynomial data 60%

Label	Accuracy	Precision	Recall	F-1 score
0		0.98	1	0.99
1	1	1	1	1




Gambar 5.5 Hasil confusion matrix SVM polynomial data 60%

5.2.2 Kernel Linear

Untuk model dengan data training 80 % menghasilkan:

Tabel 5.5 Hasil confusion matrix SVM linear data 80%

Label	Accuracy	Precision	Recall	F-1 score
0		1	0.95	0.98
1	0.99	0.99	1	1




Gambar 5.6 Hasil confusion matrix SVM linear data 80%

Untuk model dengan data training 70 % menghasilkan:

Tabel 5.6 Hasil confusion matrix SVM linear data 70%

Label	Accuracy	Precision	Recall	F-1 score
0		1	1	1
1	1	1	1	1




Gambar 5.7 Hasil confusion matrix SVM linear data 70%

Untuk model dengan data training 60 % menghasilkan:

Tabel 5.7 Hasil confusion matrix SVM linear data 60%

Label	Accuracy	Precision	Recall	F-1 score
0		0.98	1	0.99
1	1	1	1	1




Gambar 5.8 Hasil confusion matrix SVM linear data 60%

5.2.3 Kernel RBF

Untuk model dengan data training 80 % menghasilkan:

Tabel 5.8 Hasil confusion matrix SVM RBF data 80%

Label	Accuracy	Precision	Recall	F-1 score
0		1	0.91	0.95
1	0.99	0.99	1	0.99




Gambar 5.9 Hasil confusion matrix SVM RBF data 80%

Untuk model dengan data training 70 % menghasilkan:

Tabel 5.9 Hasil confusion matrix SVM RBF data 70%

Label	Accuracy	Precision	Recall	F-1 score
0		1	0.97	0.98
1	1	1	1	1




Gambar 5.10 Hasil confusion matrix SVM RBF data 70%

Untuk model dengan data training 60 % menghasilkan:

Tabel 5.10 Hasil confusion matrix SVM RBF data 60%

Label	Accuracy	Precision	Recall	F-1 score
0		1	0.98	0.99
1	1	1	1	1



Gambar 5.11 Hasil confusion matrix SVM RBF data 60%

Berdasarkan hasil confusion matrix semua model diatas yang memiliki nilai akurasi dan F1 score terbaik adalah model dengan kernel polynomial dan data training sebanyak 80%. Nilai F1 scorenya adalah 1 untuk kedua label, sedangkan akurasinya adalah 1 pula.

5.3 Pengujian Parameter Naive Bayes


Model juga dibuat dengan metode Naive Bayes , lebih spesifiknya Gaussian Naive Bayes dan Bernoulli Naive Bayes.

5.3.1 Gaussian Naive Bayes

Untuk model dengan data training 80 % menghasilkan:

Tabel 5.11 Hasil confusion matrix Gaussian Naive Bayes data 80%

Label	Accuracy	Precision	Recall	F-1 score
0		0.96	1	0.98
1	0.99	1	0.99	1




Gambar 5.12 Hasil confusion matrix Gaussian Naive Bayes data 80%

Untuk model dengan data training 70 % menghasilkan:

Tabel 5.12 Hasil confusion matrix Gaussian Naive Bayes data 70%

Label	Accuracy	Precision	Recall	F-1 score
0		0.94	1	0.97
1	0.99	1	0.99	1




Gambar 5.13 Hasil confusion matrix Gaussian Naive Bayes data 70%

Untuk model dengan data training 60 % menghasilkan:

Tabel 5.13 Hasil confusion matrix Gaussian Naive Bayes data 60%

Label	Accuracy	Precision	Recall	F-1 score
0		0.91	1	0.96
1	0.99	1	0.99	0.99



Gambar 5.14 Hasil confusion matrix Gaussian Naive Bayes data 60%

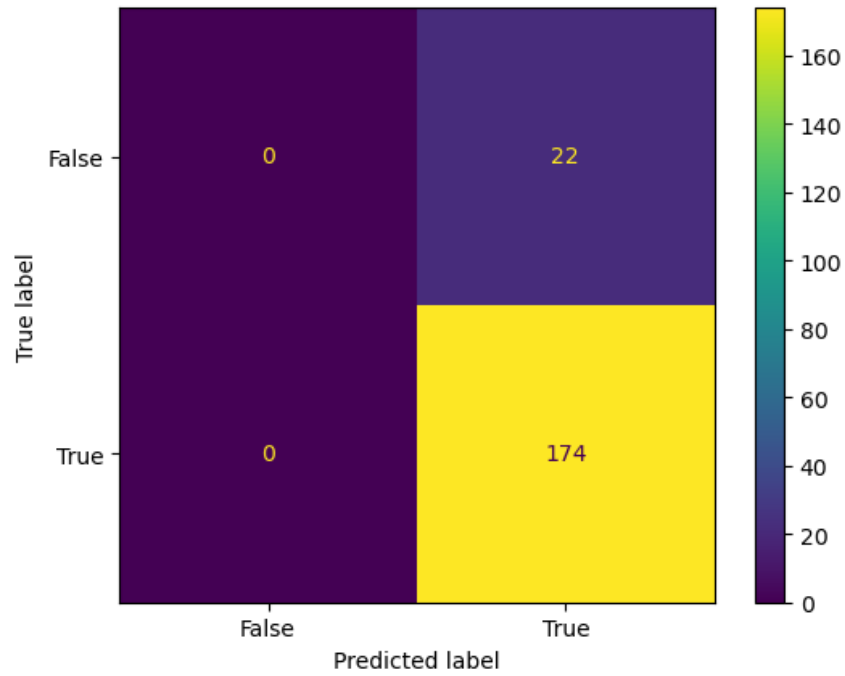
Hasil confusion matrix dari ketiga model Gaussian Naive Bayes diatas memiliki nilai akurasi yang sama yaitu pada 0.99. Maka dari itu yang akan dipilih adalah yang model pertama dengan data training 80% karena bila dibandingkan dengan yang lain memiliki F1 score yang terbaik yaitu 0.98 pada label 0 dan 1 pada label 1.

5.3.2 Bernoulli Naive Bayes

Untuk model dengan data training 80 % menghasilkan:

Tabel 5.14 Hasil confusion matrix Bernoulli Naive Bayes data 80%

Label	Accuracy	Precision	Recall	F-1 score
0		0	0	0
1	0.89	0.89	1	0.94

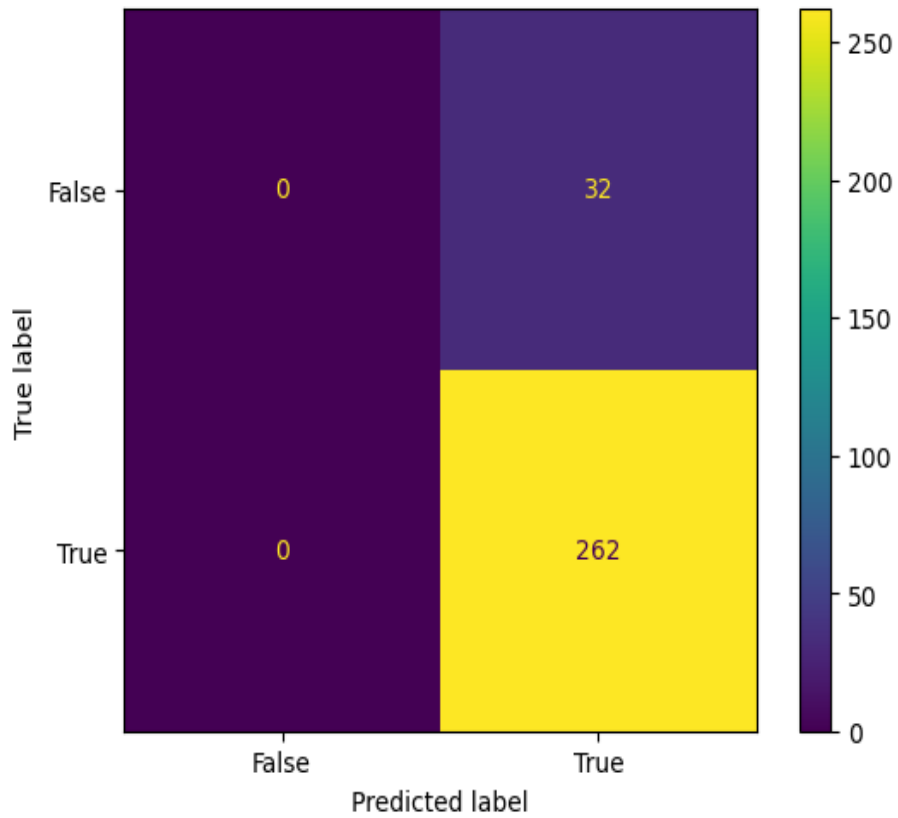


Gambar 5.15 Hasil confusion matrix Bernoulli Naive Bayes data 80%

Untuk model dengan data training 70 % menghasilkan:

Tabel 5.15 Hasil confusion matrix Bernoulli Naive Bayes data 70%

Label	Accuracy	Precision	Recall	F-1 score
0		0	0	0
1	0.89	0.89	1	0.94




Gambar 5.16 Hasil confusion matrix Bernoulli Naive Bayes data 70%

Untuk model dengan data training 60 % menghasilkan:

Tabel 5.16 Hasil confusion matrix Bernoulli Naive Bayes data 60%

Label	Accuracy	Precision	Recall	F-1 score
0		0	0	0
1	0.89	0.89	1	0.94



Gambar 5.17 Hasil confusion matrix Bernoulli Naive Bayes data 60%

Hasil pengujian confusion matrix terhadap model bernoulli naive bayes menghasilkan akurasi yang paling rendah sehingga tidak akan dipilih menjadi model akhir untuk prediksi *customer churn*.

5.4 Pengujian Implementasi Website

Website prediksi *customer churn* diakses oleh pihak perusahaan untuk melakukan prediksi *customer*. Ada 2 cara yang dapat dilakukan untuk memprediksi yaitu bisa mengisi form prediksi yang tersedia atau bila ingin melakukan prediksi banyak data sekaligus bisa dengan *upload file*. Dengan banyaknya jumlah *customer*, prediksi menggunakan *upload file* akan lebih sering digunakan.

5.4.1 Landing Page

Saat pertama masuk ke dalam *website*, *user* akan melihat tampilan sebagai berikut. Bila *user* ingin melakukan prediksi satu per satu dapat mengisi form sesuai dengan tipe data. Sedangkan bila ingin melakukan prediksi dengan banyak data bisa *upload file* csv dibagian bawah halaman.

Gambar 5.18 Landing Page

5.4.2 Error Handling

Website dilengkapi dengan error handling untuk mencegah terjadinya kesalahan dalam mengisi input.

- a. Data ada yang belum terisi

Saat user belum mengisi semua area input pada form, sistem akan mengeluarkan alert dan data tidak akan diproses.

Gambar 5.19 Error handling daerah input tidak diisi

- b. Data yang diinput tidak sesuai

Data yang harus diisi di dalam form harus sesuai dengan kriterianya masing-masing dan bila tidak sesuai akan muncul alert dan sistem tidak akan memprediksi.

The screenshot shows a web form titled "Prediksi Customer Churn" with a "Form" header. The form contains four input fields: "Jumlah Komplain" (containing 'e'), "Average Nilai Survey Data Center (1.0 - 5.0)" (containing '3.5'), "Bulan Terakhir (1.0 - 5.0)" (containing '1'), and "Average Nilai Survey Account Manager (1.0 - 5.0)" (containing '1.4'). A red "Predict" button is located at the bottom right. An error message "Please enter a number." is displayed over the "Jumlah Komplain" field. Below the form, the "Hasil Prediksi :" section shows "Model SVM: " and "Model Naive Bayes: " with empty probability fields.

Gambar 5.20 Error handling input tidak sesuai

c. File yang diupload tidak sesuai dengan template

File yang diupload agar sistem bisa memulai memprediksi harus sesuai dengan template yang telah diberikan. Template tersebut berbentuk file csv dan dapat di download di website. Bila file yang diupload tidak sesuai dengan template atau terdapat data yang kosong maka sistem tidak akan memprosesnya.

The screenshot shows an error message page with a red header labeled "ERROR". The message reads: "Data yang anda upload tidak sesuai. Pastikan file adalah .csv, sesuai template, dan tidak kosong." Below the message is a red "back" button.

Gambar 5.21 Error handling file tidak sesuai

5.4.3 Output

Terdapat 2 hasil dari sistem prediksi, prediksi dengan form akan menghasilkan keputusan yaitu churn atau tidak beserta persentasenya. Sedangkan prediksi dengan file akan menghasilkan file csv yang berisi hasil keputusan dan persentasenya pula. File tersebut akan otomatis terunduh ke device user.

The screenshot shows a web application titled "Prediksi Customer Churn". It features a "Form" section with four input fields: "Jumlah Komplain" (example: 4), "Average Nilai Survey Data Center (1.0 - 5.0)" (example: 3.7), "Nilai Survey Technical Support Tahun Terakhir (1.0 - 5.0)" (example: 2.8), and "Average Nilai Survey Account Manager (1.0 - 5.0)" (example: 4.6). A "Predict" button is located to the right of the form. Below the form, the "Hasil Prediksi" section displays the results for two models: "Model SVM: not churn dengan probabilitas 0.9574821655412" and "Model Naive Bayes: churn , dengan probabilitas 0.9999999999999147".

Gambar 5.22 Output prediksi churn lewat form

This screenshot shows a portion of the web application interface, including the "Nilai Survey Technical Support Tahun Terakhir (1.0 - 5.0)" input field (example: 2.8) and the "Average Nilai Survey Account Manag" input field (example: 4.6). A notification box in the top right corner indicates that a file named "hasil.csv" (2,604 B) has been successfully downloaded.

Gambar 5.23 Output prediksi churn lewat upload file

5.5 Hasil Feedback dari PT X

Wawancara dilaksanakan pada Senin, 27 Mei 2024 bersama perwakilan dari PT X. Wawancara diawali dengan menjelaskan secara garis besar alur pembuatan model serta mendemokan bagaimana cara kerja dari website sederhana yang telah dibuat. Selama pertemuan berlangsung ada beberapa pertanyaan yang diberikan bertujuan untuk mencatat feedback dari PT X.

Pertanyaan : Apakah ada ekspektasi awal saat menerima dan mendengar proposal dari proyek penelitian prediksi *customer churn* ini ?

Jawab : Tentunya ada, saat awal mendengar proposal dan dijelaskan mengenai gambaran dari proyek ini, ekspektasinya adalah bisa menunjukkan *customer* yang akan *churn* berdasarkan data - data yang telah ada secara cepat

Pertanyaan : Apakah ekspektasi awal tersebut terpenuhi?

Jawab : Lebih ke arah kaget karena ternyata dari data - data yang kemarin diberikan bisa benar - benar menghasilkan jawaban yang konkrit

Pertanyaan : Apakah dengan adanya model prediksi dapat membantu keberlangsungan bisnis, jika iya bagaimana bisa membantu?

Jawab : Tentunya sangat membantu mempermudah mengidentifikasi *customer - customer* mana yang harus di *treatment* lebih khusus. Model ini dapat membuat proses identifikasi *customer* menjadi lebih efisien dan meminimalisir kesalahan karena analisis yang sebelumnya hanya dilakukan secara manual. Selain itu, sebelumnya tidak ada faktor - faktor khusus yang menjadi tanda *customer* akan *churn*, dan dengan analisis korelasi yang telah dilakukan maka model ini dapat terpercaya.

Pertanyaan : Apakah atribut - atribut yang digunakan dalam membuat model ini sudah sesuai bila dijadikan faktor dalam *customer churn*?

Jawab : Menurut saya sudah sesuai, dan saya pun percaya karena sudah dihitung pula melalui korelasi berdasarkan data yang telah ada. Sebelumnya dari tim kami hanya memperhatikan *komplain* sebagai tanda bahwa pelanggan belum puas, ternyata ada faktor - faktor lain yang harus diperhitungkan.

Pertanyaan : Apakah ada tindakan yang akan dilakukan untuk menindaklanjuti prediksi - prediksi ini ?

Jawab : Tentunya ada, untuk *customer* yang terprediksi *churn* akan dilakukan *treatment* khusus dan akan dihubungi serta di *check up* lebih sering oleh tim kami agar *customer* tersebut tidak *churn*

Pertanyaan : Adakah feedback atau masukan untuk website prediksi *customer churn* ini ?

Jawab : Mungkin saya ingin ditambahkan rata - rata transaksi yang dilakukan *customer* per tahunnya di bagian yang *upload file* untuk membantu mengidentifikasi lagi seberapa urgentnya, dan minta tolong hasilnya diubah dalam bentuk *file* saja.