

## BAB 2

### TINJAUAN PUSTAKA DAN DASAR TEORI

#### 2.1. Tinjauan Pustaka

Kumpulan data sangat berguna bagi setiap organisasi dan aktivitas bisnis. Hal ini karena dengan pengolahan yang tepat maka data-data tersebut dapat menghasilkan informasi yang bermanfaat. Namun kumpulan data yang besar dan kompleks tidak dapat dianalisis secara manual. Hal ini menyebabkan informasi yang berguna sering terabaikan sehingga keuntungan dari penggunaan data tidak dimanfaatkan secara optimal (Khan dkk, 2011). Penemuan informasi ini dapat dilakukan dengan menerapkan *data mining*. *Data mining* adalah proses penggalian menggunakan teknik statistik, matematika, kecerdasan buatan, dan *machine learning* untuk mendapatkan informasi dari kumpulan data yang besar (Anggraeni dkk, 2013).

*Retail* merupakan salah satu area aplikasi utama untuk *data mining* karena menyimpan berbagai macam data selama aktivitas bisnisnya. Data-data tersebut antara lain data transaksi, data persediaan, dan data *supplier*. *Retail* atau yang biasa disebut dengan toko merupakan perusahaan yang melakukan pembelian barang dari perusahaan lain dan menjual kembali produk-produk tersebut ke konsumen (Preuss, 2013). Pada industri manufaktur, selalu ada *item* yang memiliki tingkat permintaan lebih tinggi dibandingkan *item* lain dan terdapat *item* yang jarang atau bahkan tidak dibutuhkan selama bertahun-tahun (Mitra, 2015). Sama seperti industri manufaktur, salah satu kondisi yang selalu terjadi pada usaha *retail* adalah perbedaan tingkat permintaan antar *item* yang dijual. *Item* yang jarang dan tidak dibutuhkan pada suatu industri manufaktur atau barang yang tidak laku di suatu usaha *retail* menyebabkan terjadinya fenomena *deadstock*. *Deadstock* merupakan *item* yang tidak dibutuhkan atau tidak terjual dalam waktu yang lama. Fenomena *deadstock* dapat diidentifikasi dengan mengetahui pola *fast*, *slow*, dan *non moving item*. Pola tersebut dapat dicari dengan menerapkan *data mining*.

Pengklasifikasian *item* kedalam kategori *fast*, *slow*, dan *non moving item* dapat dilakukan dengan metode *clustering*. Penelitian yang dilakukan oleh Joshi dkk (2015) menyatakan bahwa keputusan bisnis dapat dilakukan dengan melakukan *data mining*. Salah satunya dengan dilakukannya pengklasifikasian segmentasi barang ke dalam kategori *deadstock* (DS), *slow moving* (SM), dan *fast moving*

(FM) *item*. Penelitian serupa juga dilakukan oleh Wijaya (2014) di perusahaan *retail* yang bergerak di bidang perdagangan *furniture*. Penelitian dilakukan dengan mengumpulkan data transaksi usaha dagang untuk mengelompokkan produk berdasarkan tingkat penjualannya. Analisis dilakukan dengan menggunakan algoritma *fuzzy c-means*. Selain itu terdapat penelitian oleh Khan dkk (2011) yang mengklasifikasikan dan mengekstraksi pola dari *customer data* yang tersimpan dalam *database*. Penelitian dibagi menjadi 2 tahapan. Tahapan pertama yaitu membagi *stock* kedalam kategori *deadstock* (DS), *slow moving* (SM), dan *fast moving* (FM) *item*. Tahap selanjutnya yaitu menerapkan algoritma Most Frequent Pattern (MFP). Tidak hanya pada perusahaan *retail*, pengelompokan data juga dapat diterapkan dalam dunia kesehatan. Salah satu penelitian dilakukan oleh Sulastri dan Gufroni (2017) menjelaskan mengenai penerapan *data mining* untuk tujuan mengelompokkan data kriteria penderita *thalassaemia* berdasarkan catatan rekam medik rumah sakit. Informasi tersebut selanjutnya dijadikan acuan dalam pelaksanaan transfusi.

Selain dengan menggunakan metode *clustering*, pengelompokan suatu *item* dapat dilakukan dengan menerapkan metode *classification*. Sebuah penelitian mengenai manajemen persediaan oleh Kumar dkk (2017) dilakukan untuk mengatur persediaan sebuah pabrik spons besi dengan cara mengklasifikasikan *spare part* kedalam 3 kategori. Analisis yang diterapkan adalah *FSN Analysis* berdasarkan *turnover ratio*. *Spare part* dibagi ke dalam 3 kategori yaitu *fast moving*, *slow moving*, dan *non moving item*. *FSN Analysis* dipilih karena dapat membantu pabrik tersebut mengatur permasalahan kelebihan dan kekurangan persediaan. Selain itu Mitra dkk (2015) juga menerapkan *FSN Analysis* pada industri manufaktur karena pada industri manufaktur tidak semua *item* dibutuhkan dalam jumlah yang sama. *Item* dibagi ke dalam 3 kategori yaitu *fast moving*, *slow moving*, dan *non moving item*. Data yang digunakan pada penelitian yaitu *annual demand* setiap *item*, *turnover ratio*, *unit price* setiap *item*, dan *cumulative annual usage* setiap *item*.

Tidak berhenti pada penemuan pola data saja, pola data tersebut dapat disajikan menjadi informasi yang bermanfaat bagi perusahaan. Seperti pada tinjauan pustaka terkait, informasi yang dihasilkan dari *data mining* dapat dijadikan sebagai pertimbangan dalam pengambilan keputusan. Informasi mengenai *deadstock* pada *retail* dapat digunakan sebagai pertimbangan pengambilan keputusan dalam manajemen persediaan. Devarajan dan Jayamohan (2015)

menyatakan bahwa keputusan dalam manajemen persediaan dapat diambil dari hasil kombinasi analisis manajemen persediaan. Berbagai analisis manajemen persediaan seperti FSN, XYZ, VED, ABC memiliki keterbatasannya masing-masing jika diaplikasikan sendiri. Setiap analisis hanya mampu mengklasifikasikan setiap *item* ke dalam kategori, namun dengan menggabungkan dua atau lebih analisis maka dapat dijadikan untuk menyusun sistem pengendalian persediaan yang sesuai. *FSN Analysis* dapat digabungkan dengan *XYZ Analysis* untuk membantu perusahaan kimia menentukan *item* yang harus dihentikan dan mana *item* yang harus diselamatkan. Berdasarkan hasil analisis maka *item* yang tergolong kedalam kategori NX merupakan *item* yang harus dihentikan. Maka, setelah diketahui pola *slow moving*, *fast moving*, dan *non moving item*, dapat dilakukan analisis tambahan guna mengambil keputusan berdasarkan informasi yang didapatkan dari *data mining*.

Banyaknya data dan kompleksnya data mengakibatkan proses *data mining* tidak dapat dilakukan secara manual. Sehingga selama prosesnya diperlukan bantuan *software* untuk mempermudah dan mempercepat kalkulasi. Berdasarkan ulasan Ganas (2009), *data mining* dapat dilakukan dengan menggunakan *Microsoft Excel 2007* dan *SQL Server 2008*. *Microsoft Excel 2007* menyediakan berbagai macam *tools* untuk menganalisis data. Selain itu *data mining* dan KDD (Knowledge Discovery) dapat dilakukan dengan menggunakan *software Rapid Miner* (Hofmann dan Klikeberg, 2013). *Rapid Miner* dapat digunakan untuk mencari pola beli konsumen dengan menerapkan *market basket analysis*. Berbagai macam *software* dapat digunakan untuk melakukan *data mining*. Pemilihan *software* pada dasarnya dipengaruhi oleh kebutuhan analisis data dan kemampuan *software* masing-masing.

Berdasarkan uraian dari penelitian terkait, pada penelitian ini dilakukan *data mining* untuk mengklasifikasikan *item* kedalam tiga kategori yaitu *fast moving*, *slow moving*, dan *non moving item* dengan menggunakan metode *classification*. Klasifikasi dilakukan dengan menerapkan *FSN Analysis* berdasarkan *turnover ratio*. Setelah *deadstock* diidentifikasi, dilakukan *XYZ Analysis* guna membantu *minimarket* dalam penanganan *deadstock*.

## **2.2. Dasar Teori**

### **2.2.1. Definisi *Data Mining***

*Data mining* merupakan proses menemukan informasi tersembunyi yang berpotensi bermanfaat dengan mengekstrasinya dari sekumpulan data yang tidak lengkap, kotor, dan acak (Sahu dkk, 2010).

*Data mining* dapat didefinisikan sebagai suatu proses menemukan informasi penting dari sekumpulan data yang besar. *Data mining* merupakan pencarian model dan pola dari sekumpulan data yang terdapat di dalam *database* yang dapat memberikan keuntungan kompetitif dalam bisnis (Sumathi dan Sivanandam, 2006).

Perbedaan mendasar antara *data mining* dengan *data analysis* sederhana yaitu *data mining* bertujuan untuk menggali informasi dan menemukan pengetahuan pada premis yang tidak memiliki asumsi yang jelas. Seiring berkembangnya teknologi dan informasi secara pesat serta meningkatnya penumpukan jumlah data di zaman *modern* maka pendekatan penggalian data dituntut semakin otomatis dan efektif. Berdasarkan penjelasan tersebut maka dapat disimpulkan bahwa *data mining* merupakan proses pencarian pola atau *trend* dari kumpulan data yang tersimpan dalam *database* guna membantu dalam pengambilan keputusan di masa yang akan datang.

### **2.2.2. Tahapan Proses dalam *Data mining***

Proses *data mining* pada umumnya disebut sebagai *knowledge discovery from data (KDD)* namun beberapa berpandangan bahwa *data mining* merupakan salah satu tahapan penting dalam KDD. Walaupun *data mining* dan KDD sering dianggap sebagai satu hal yang sama, sesungguhnya *data mining* merupakan bagian dari KDD. KDD merupakan rangkaian proses yang terdiri dari beberapa tahapan yang bersifat iteratif dan interaktif dimana tahapan dilakukan secara berulang dan pemakai terlibat langsung dalam prosesnya. Berikut merupakan tahapan KDD (Han dkk, 2012):

#### **a. *Data Cleaning***

*Data cleaning* merupakan tahap membersihkan kumpulan data dari data *noise* atau data yang tidak relevan.

b. *Data Integration*

Kumpulan data yang diolah dapat diperoleh dari berbagai sumber *database*. *Data integration* merupakan tahap penggabungan berbagai data yang terdapat dari berbagai sumber.

c. *Data Selection*

Tidak semua data yang terdapat pada *database* digunakan dalam proses *data mining*. Pada tahap ini dilakukan proses pemilahan data yang akan digunakan untuk dianalisis.

d. *Data Transformation*

*Data transformation* merupakan tahap mengubah data yang telah melalui tahap seleksi ke dalam format yang sesuai untuk di proses ke dalam *data mining*. Perubahan bentuk dapat dilakukan dengan cara meringkas data atau proses agregasi.

e. *Data mining*

Pada proses *data mining* dilakukan dengan menerapkan sebuah metode guna mengetahui informasi penting yang tersembunyi dalam kumpulan data tersebut.

f. *Pattern Evaluation*

Informasi yang terkandung dalam kumpulan data yang telah terpilih pada umumnya akan membentuk suatu pola. Pada tahap ini dilakukan identifikasi pola yang terdapat dalam kumpulan data.

g. *Knowledge Presentation*

*Knowledge presentation* merupakan tahap menyajikan informasi yang didapatkan dari proses *data mining* untuk membantu sebagai bahan pertimbangan dalam pengambilan keputusan.

Secara singkat, tahapan proses dalam *data mining* dapat dirangkum ke dalam tiga tahap utama yaitu (Ramageri, 2010):

a. *Exploration*

*Exploration* merupakan langkah membersihkan kumpulan data dari data kotor sehingga hanya terdapat data-data yang penting dan relevan saja. Selanjutnya kumpulan data tersebut diubah ke dalam format yang sesuai ke dalam proses *data mining*.

b. *Pattern identification*

Pada tahap ini dilakukan identifikasi pola tersembunyi yang terdapat dalam kumpulan data.

c. *Deployment*

Pola data atau informasi yang telah ditemukan digunakan sebagai acuan dalam mengambil keputusan sesuai dengan hasil yang diinginkan.

### 2.2.3. Metode dalam *Data Mining*

Secara umum terdapat 4 metode *data mining* berdasarkan fungsinya (Yunus, 2010):

a. *Classification*

*Classification* merupakan metode mengelompokkan data ke dalam kelas-kelas yang telah ditetapkan.

b. *Clustering*

Berbeda dengan *classification*, *clustering* mengelompokkan data ke dalam kelas-kelas yang tidak distandarkan sehingga algoritma akan mencoba mengelompokkan data yang serupa.

c. *Regression*

*Regression* merupakan proses menemukan fungsi dari model data dengan sedikit kesalahan.

d. *Association Rule Learning*

*Association rule learning* berfokus pada menemukan aturan asosiatif antara kombinasi *item*. Salah satu contohnya adalah menemukan keterkaitan antar produk yang dibeli oleh konsumen pada suatu minimarket yang berguna dalam membantu strategi pemasaran produk.

### 2.2.4. *FSN Analysis (Fast Moving, Slow Moving, Non Moving Analysis)* Berdasarkan *Turnover Ratio*

*FSN Analysis* merupakan analisis yang mengklasifikasikan material ke dalam 3 kategori berdasarkan laju konsumsi material. Pada *FSN Analysis*, material dikategorikan menjadi *fast moving*, *slow moving*, dan *non moving item* berdasarkan frekuensi transaksi (Devarajan dan Jayamohan, 2015). Pada umumnya produk yang tergolong sebagai *fast moving* pada suatu usaha *retail* adalah air mineral dalam kemasan dan mi instan sedangkan *slow moving item* merupakan *item* yang laju konsumsinya lambat seperti sabun cuci dan makanan ringan. Salah satu permasalahan yang sering ditemui dalam suatu industri yaitu tidak semua *item* dibutuhkan dalam jumlah yang sama, akan selalu terdapat sekumpulan *item* yang dibutuhkan dalam jumlah yang banyak sedangkan di sisi lain akan selalu terdapat sekumpulan *item* yang jarang dibutuhkan atau bahkan

tidak terdapat permintaan selama beberapa waktu yang lama. *FSN Analysis* bermanfaat untuk mengidentifikasi dan mengatasi barang usang (barang tidak laku). Pada umumnya, analisis ini dapat digunakan untuk membantu dalam pengaturan *stock* toko, distribusi, dan membantu menentukan metode untuk penanganan *item* tersebut. Berikut merupakan pembagian kategori klasifikasi berdasarkan *FSN Analysis* (Devarajan dan Jayamohan, 2015):

- a. *Fast moving* (F) : merupakan sekumpulan item yang memiliki *turnover ratio* lebih besar dari 3.
- b. *Slow moving* (S) : merupakan sekumpulan item yang memiliki *turnover ratio* diantara 1 dan 3.
- c. *Non moving* (N) : merupakan sekumpulan item yang memiliki *turnover ratio* dibawah 1.

Data-data yang dibutuhkan untuk perhitungan *FSN Analysis* berdasarkan *turnover ratio* yaitu daftar *item*, *annual demand* setiap *item*, dan *average inventory* setiap *item*. *Turnover ratio* setiap *item* ditentukan dengan membagi *annual demand* dengan *average inventory* setiap *item*. *Turnover ratio* merupakan perbandingan yang menunjukkan seberapa efektif persediaan dikelola dengan mengukur berapa kali perusahaan menjual total persediaan rata-rata selama suatu periode. Hal inilah yang nantinya dijadikan dasar dalam menentukan kategori setiap *item*. Setiap kategori membutuhkan perlakuan yang berbeda sehingga memerlukan kebijakan dan model persediaan masing-masing.

Berikut merupakan langkah dalam penerapan metode *FSN Analysis* berdasarkan *turnover ratio*.

- a. Menghitung *average inventory* tiap *item* per bulan

$$\text{Average inventory} = \frac{\text{stok awal} + \text{stok akhir}}{2} \quad (2.1)$$

- b. Menghitung *average inventory* total dengan menghitung rata-rata dari seluruh *average inventory* selama 6 bulan.

$$\text{Average inventory total} = \frac{\sum_{i=1}^n \text{average inventory}_i}{6} \quad (2.2)$$

- c. Menghitung *total demand*

$$\text{Total demand} = \sum_{i=1}^n \text{demand}_i \quad (2.3)$$

- d. Menghitung *turnover ratio*

$$\text{Turn over ratio} = \frac{\text{Average inventory total}}{\text{total demand}} \quad (2.4)$$

- e. Mengklasifikasikan item sesuai kategori pada analisis FSN berdasarkan turnover ratio.

### 2.2.5. XYZ Analysis (berdasarkan stock value)

XYZ Analysis merupakan analisis yang mengklasifikasikan sekumpulan *item* ke dalam 3 kategori yaitu X, Y, dan Z berdasarkan *inventory value*. Berikut merupakan pembagian kategori klasifikasi berdasarkan XYZ Analysis (Devarajan dan Jayamohan, 2015) :

- a. X Class: sekumpulan *item* yang termasuk ke dalam 70% pertama dari total *inventory value*. Item pada kelas X tergolong sebagai *item* yang penting sehingga memerlukan pengawasan dan penanganan yang ketat.
- b. Y Class: sekumpulan *item* yang termasuk ke dalam 20% selanjutnya setelah kelas X. *Item* pada kelas Y tergolong sebagai *item* yang tidak terlalu penting dibandingkan *item* pada kelas X sehingga hanya memerlukan pengawasan yang standar.
- c. Z Class: sekumpulan *item* yang termasuk ke dalam 10% terakhir dari total *inventory value*. Item pada kelas Z tidak membutuhkan pengawasan yang ketat dan seringkali disebut sebagai “*free stock*” atau *forward holding*.

Data-data yang dibutuhkan untuk melakukan perhitungan XYZ Analysis yaitu data *current stock* dan *unit cost* setiap item. Berikut merupakan langkah-langkah yang diperlukan untuk melakukan XYZ Analysis:

- a. Hitung *stock value* dengan mengkalikan nilai *current stock* setiap *item* dengan masing-masing *unit cost*.

$$stock\ value = current\ stock \times unit\ cost \quad (2.5)$$

- b. Urutkan *stock value* dari nilai terbesar ke nilai terkecil.
- c. Hitung persentase *stock value* dan kumulatif persentase *stock value*.

$$\% stock\ value_i = \frac{stock\ value_i}{\sum stock\ value} \times 100\% \quad (2.6)$$

- d. Klasifikasikan *item* sesuai pembagian kategori klasifikasi XYZ Analysis.

XYZ Analysis bertujuan untuk mengevaluasi fluktuasi permintaan dari *item-item* yang terdapat pada toko. Analisis ini membantu dalam mengawasi nilai rata-rata persediaan dan berfokus untuk mengurangi persediaan.

### 2.2.6. Kombinasi XYZ Analysis dan FSN Analysis

Pada suatu industri, selalu ada *item* yang memiliki tingkat permintaan lebih tinggi dibandingkan *item* lain dan terdapat *item* yang jarang atau bahkan tidak dibutuhkan selama bertahun-tahun. Barang tidak laku tersebut dapat diidentifikasi dengan menerapkan FSN Analysis berdasarkan *turnover ratio*. Namun, berbagai analisis manajemen persediaan seperti FSN, XYZ, VED, ABC memiliki keterbatasannya masing-masing jika diaplikasikan sendiri. Setiap analisis hanya mampu mengklasifikasikan setiap *item* ke dalam kategori masing-masing. Ketika terdapat banyak *deadstock*, maka *deadstock* tersebut tidak dapat sembarang dihentikan pembeliannya dari *supplier*. Hal ini karena setiap analisis hanya melihat dari satu sisi saja seperti pada FSN Analysis yang hanya melihat berdasarkan *turnover ratio*. Namun dengan menggabungkan dua atau lebih analisis maka keputusan dapat diambil (Devarajan dan Jayamohan, 2015).

Analisis kombinasi dilakukan dengan menerapkan XYZ Analysis pada kategori N *item* (*deadstock*) hasil FSN Analysis. Hal ini dilakukan untuk membantu mengetahui *deadstock* yang perlu diprioritaskan untuk dihentikan pembeliannya dari *supplier* berdasarkan *stock value* nya. Berikut merupakan pembagian kategori klasifikasi berdasarkan kombinasi XYZ Analysis pada N *item* hasil FSN Analysis:

- a. NX : merupakan sekumpulan *deadstock* yang termasuk ke dalam 70% pertama dari total *inventory value* sehingga tergolong penting dan memerlukan pengawasan dan penanganan yang ketat.
- b. NY : merupakan sekumpulan *deadstock* yang termasuk ke dalam 20% selanjutnya setelah kelas NX sehingga tidak terlalu penting dibandingkan *item* pada kelas NX dan hanya memerlukan pengawasan yang standar.
- c. NZ : merupakan sekumpulan *deadstock* yang termasuk ke dalam 10% terakhir dari total *inventory value* sehingga tidak membutuhkan pengawasan yang ketat.