

BAB 2

TINJAUAN PUSTAKA DAN DASAR TEORI

2.1. Tinjauan Pustaka

Retailing adalah usaha bisnis dengan memasarkan barang, jasa, ataupun gabungan keduanya kepada konsumen akhir yang menggunakannya sebagai konsumsi untuk pemenuhan kebutuhan rumah tangga (Berman dan Evans, 1997). Kebutuhan konsumen yang beragam menyebabkan item yang dijual retail menjadi bervariasi atau *multi-item* yakni variasi jenis produk yang banyak dengan berbagai kategori dan merk. Produk *multi-item* pada retail menimbulkan fenomena perilaku *purchase dependence* pada konsumen, yakni perilaku yang membeli suatu item dan akan membeli item lainnya karena memiliki keterkaitan bagi konsumen. Pada perilaku *purchase dependence* ini, apabila ada suatu *item* mengalami ketidaktersediaan (*stock-out*) dapat menyebabkan pembatalan transaksi *item* lainnya yang stoknya masih ada (Park dan Seo, 2013).

Dalam menghadapi fenomena *purchase dependence*, pihak retail perlu mengetahui *item* yang tergolong *purchase dependence item*. Informasi *purchase dependence item* dapat diketahui dengan melakukan penggalian data transaksi atau disebut *data mining*. Menurut Han dan Kamber (2011), *data mining* merupakan sebuah proses dimana sebuah metode diterapkan untuk mengekstrak pola data dari sejumlah data mentah. Terdapat beberapa metode pada data mining. Salah satu metode untuk menemukan sebuah keterkaitan adalah dengan metode *association rules*. Bala dkk (2010) menguji metode *data mining* yakni *association rule* pada suatu data transaksi untuk menggambarkan *purchase dependence*. Hasil dari data mining yang dilakukannya adalah aturan-aturan keterkaitan (asosiasi) suatu pasangan item yang berkaitan bagi konsumen.

Pada metode *association rules*, terdapat beberapa algoritma yang digunakan untuk menentukan kombinasi *item* dengan pertimbangan pola frekuensi tertinggi atau pasangan yang banyak muncul pada total data. Algoritma yang sering digunakan adalah algoritma apriori dan algoritma *FP-growth*. Pada penelitian yang dilakukan oleh Buulolo (2013), algoritma apriori diimplementasikan pada data penjualan obat di suatu apotek. *Association rules* dengan algoritma apriori digunakan untuk mendeteksi obat-obatan yang dibeli bersamaan. Kemudian terdapat penelitian dari Tampubolon dkk (2013) yang juga mengimplementasikan

algoritma apriori pada data penjualan alat-alat kesehatan. Penelitian ini menghasilkan kombinasi dari item yang terkait untuk mengetahui informasi penting yang dapat meningkatkan penjualan dan pelayanan.

Selain algoritma apriori, terdapat pula algoritma *FP-growth*. Gunadi dan Sensuse (2012) menerapkan *data mining* pada data penjualan produk buku pada suatu percetakan untuk memberikan bahan pertimbangan dalam pembuatan strategi pemasaran dan penjualan. Data mining yang dilakukan menggunakan metode *association rules* dan dua algoritma, yakni algoritma apriori dan algoritma *frequent pattern growth* (FP-growth). Penelitian ini menghasilkan tingkat kekuatan aturan asosiasi dari kedua algoritma, dimana algoritma apriori memiliki tingkat kekuatan lebih tinggi dibandingkan algoritma *FP-growth*.

Data mining dapat dilakukan dengan bantuan *software* untuk mempersingkat waktu kalkulasi agar lebih cepat dalam menemukan pola data. *Software* yang digunakan pada penelitian Gunadi dan Sensuse (2012) adalah *software Weka 3.6*. *Software Weka 3.6* secara otomatis dapat mengolah *dataset* dan menghasilkan aturan-aturan asosiasi antar item sesuai dengan algoritma yang diinginkan. Kemudian *software data mining* lainnya adalah Program Tanagra. Tampubolon dkk (2013) menggunakan *software* Tanagra versi 1.4 untuk mendapatkan aturan asosiasi. *Software* ini memiliki metode *association rules* dan hanya terdapat satu algoritma, yakni algoritma apriori. Hasil dari pengolahan dengan *software* Tanagra adalah aturan-aturan asosiasi sesuai *dataset* yang diinputkan.

Dalam memperkuat pentingnya informasi dari *data mining* untuk menghadapi fenomena *purchase dependence*, dibutuhkan bukti dari observasi atau penggambaran keadaan langsung dari suatu retail yang bersangkutan. Bala dkk (2010) melakukan penelitian pada toko bahan makanan pada dua periode waktu, masing-masing selama 15 hari. Pada periode pertama (periode-I), observasi dilakukan tanpa mempertimbangkan *association rules* dan pada periode kedua (periode-II) mempertimbangkan *association rules* untuk tujuan penambahan persediaan. Hasil dari penelitian ini adalah terbukti bahwa periode-II dengan pertimbangan peraturan asosiasi telah menghasilkan profit yang lebih besar bagi toko.

Selain penelitian tersebut, penelitian yang juga mendukung pentingnya informasi *purchase dependence item* adalah penelitian dari Park dan Seo (2013).

Penelitian ini menunjukkan pentingnya pengaruh *purchase dependence* pada suatu persediaan terutama dampaknya pada biaya persediaan. Model kebijakan persediaan yang dirancang yakni model EOQ dengan mempertimbangan *purchase dependence* dan terbukti menghasilkan biaya persediaan yang rendah. Bala (2012) juga membuktikan bahwa informasi dari *data mining* terkait *purchase dependence* penting untuk kelangsungan usaha, terutama dalam hal *replenishment*. Telah terbukti bahwa salah satu modelnya yakni model *joint replenishment* memberikan hasil biaya persediaan yang minimum.

Dalam kontrol persediaan, suatu retail harus mengetahui *key product* atau *item* yang memberikan dampak krusial bagi jalannya bisnis retail tersebut. Klasifikasi ABC digunakan untuk mengelompokkan barang-barang dengan kriteria banyaknya kontribusi pada penjualan sehingga dapat diketahui item yang memiliki dampak besar bagi suatu perusahaan (Ramanathan, 2006). Hasil dari klasifikasi ini adalah pengelompokkan item-item ke dalam kelas A, B, dan C. Dengan adanya klasifikasi ini, dapat diketahui *purchase dependence item* yang dihasilkan dari data mining termasuk pada kelas A, B, atau C. Jika termasuk kategori yang berkontribusi besar bagi penjualan, maka akan semakin memperkuat informasi *data mining* untuk diketahui oleh pihak retail.

Berdasarkan uraian dari beberapa penelitian yang telah dilakukan, penelitian yang akan dilakukan adalah menerapkan *data mining* pada ruang lingkup retail dengan metode *association rules* dan algoritma apriori. *Data mining* dilakukan untuk memberikan informasi keterkaitan barang sesuai perilaku *purchase dependence*. Selain itu juga dilakukan klasifikasi ABC dan penggambaran *demand* yang akan memperkuat informasi *data mining* untuk diketahui oleh pihak retail.

2.2. Dasar Teori

Pada sub bab ini berisi dasar-dasar teori yang berkaitan dengan penelitian.

2.2.1. Pengertian dan Jenis-jenis Retail

Lingkup yang dibahas pada penelitian adalah ruang lingkup pada obyek retail. Terdapat beberapa pengertian retail dari para ahli, yakni sebagai berikut.

b. Menurut Kotler dan Keller (2011)

Retailing merupakan semua aktivitas yang termasuk penjualan barang atau jasa secara langsung pada konsumen akhir untuk penggunaan yang bersifat pribadi, bukan untuk bisnis.

c. Menurut Levy dan Weitz (2007)

Retailing adalah rangkaian aktivitas bisnis untuk menambah nilai guna barang dan jasa yang dijual kepada konsumen untuk dikonsumsi sendiri, bukan untuk dijual lagi.

d. Menurut Berman dan Evans (1997)

Retailing adalah usaha bisnis dengan memasarkan barang, jasa, ataupun gabungan keduanya kepada konsumen akhir yang menggunakannya sebagai konsumsi untuk pemenuhan kebutuhan rumah tangga.

Terdapat beberapa jenis atau tipe dari retail. Retail dengan klasifikasi toko pengecer dapat dibedakan menjadi beberapa tipe, salah satunya berdasarkan produk-produk yang dijual. Menurut Kotler and Keller (2011), terdapat tujuh tipe toko pengecer yang utama, yaitu:

a. Toko Khusus (*Specialty store*)

Toko ini menjual produk dengan jenis produk dengan cakupan yang sempit, seperti toko pakaian, toko alat olahraga, toko furnitur, toko bunga, atau toko buku. Sehingga bisa dikatakan dalam satu toko hanya menjual suatu jenis produk yang spesifik.

b. Toko Serba Ada (*Department store*)

Toko yang menjual berbagai jenis produk dengan berbagai pilihan mutu, biasanya terdiri dari pakaian, furnitur rumah, atau perabotan rumah tangga. Setiap lini produk beroperasi sebagai departemen yang terpisah.

c. Toko Swalayan (*Supermarket*)

Toko ini merupakan tipe retail yang cukup besar dan bervolume tinggi. Toko swalayan melayani berbagai kebutuhan konsumen dengan berbagai produk yakni bahan makanan seperti daging dan ikan segar, sayur dan buah-buahan, makanan atau minuman kaleng, produk sabun dan kebersihan, juga peralatan rumah tangga.

d. Toko Kebutuhan Sehari-hari (*Convenience Store*)

Retail ini biasanya terletak di daerah permukiman, relatif kecil, dan memiliki jam buka yang panjang. Tingkat perputaran pada toko jenis ini tinggi, namun dengan produk yang terbatas seperti minuman, makanan ringan, rokok, dll.

e. Toko Diskon (*Discount store*)

Merupakan retail yang menjual barang-barang standar dengan harga yang lebih murah, margin lebih rendah, dan menjual dengan volume yang lebih tinggi atau semacam grosir.

f. *Off-price retailer*

Merupakan pengecer yang memberikan potongan harga sehingga harga lebih rendah daripada harga grosir, dan harga yang ditawarkan lebih murah dibandingkan harga eceran.

g. *Superstore*

Retailing yang merupakan kombinasi dari toko swalayan dan toko diskon yang menjual dengan harga murah. Toko ini bertujuan untuk memenuhi kebutuhan konsumen untuk pembelian produk bahan makanan atau bukan bahan makanan. Toko ini juga menawarkan berbagai pelayanan seperti pencucian, perbaikan perabot, pembayaran tagihan, atau makanan murah.

2.2.2. *Purchase Dependence*

Kebutuhan konsumen yang beragam menyebabkan item yang dijual retail menjadi bervariasi atau *multi-item* yakni variasi jenis produk yang banyak dengan berbagai kategori dan merk. Produk *multi-item* pada retail menimbulkan fenomena perilaku *purchase dependence* pada konsumen. Menurut Park dan Seo (2013) *purchase dependence* merupakan suatu fenomena yang terjadi dikarenakan perilaku pembelian suatu *item* yang tergantung dari ketersediaan suatu *item* lain pada suatu transaksi yang sama. *Purchase dependence* berbeda dengan *demand dependence*. *Purchase dependence* berkaitan dengan perilaku pembelian konsumen, sedangkan *demand dependence* berkaitan dengan korelasi antar permintaan. Fenomena *purchase dependence* dapat dilihat dari analisis data transaksi masa lalu. Jika suatu transaksi yang terdiri dari beberapa *item* terdapat satu *item* saja yang mengalami ketidaktersediaan (*stock-out*) maka order tersebut akan dibatalkan oleh pembeli, walaupun stok *item* lainnya tersedia.

Zhang dkk (2011) menyebutkan bahwa *purchase dependence* terjadi karena adanya perilaku pembelian konsumen yang disebut *cross-selling*. Pada *cross-selling* terdapat *item* mayor dan minor. Pembelian terdapat *item* mayor dapat menyebabkan penambahan permintaan untuk *item* minor juga.

Masalah dari persediaan dengan barang multi-*item* lebih rumit karena terdapat fenomena *purchase dependence* diantara *item* atau *item-set* (menunjuk pada satu *item* atau beberapa *item*). Pada banyak situasi yang pernah ada, pembeli melakukan pembelian barang jika hanya *item* lainnya yang ingin dibeli juga tersedia, atau dapat dikatakan pembeli ingin membeli keduanya. Untuk memperjelasnya, Bala (2008) memberikan contoh yakni misalnya pada suatu toko, *item* B tersedia dan *item* A tidak tersedia. Seorang pembeli tertarik untuk membeli *item* B, namun asal *item* A juga tersedia di toko, sehingga dia bisa membeli keduanya. Dari situasi tersebut, dapat dikatakan bahwa tidak masalah jika stok B tidak ada. Sebaliknya, jika *item* A tidak ada dalam stok, maka tidak akan ada pembelian untuk stok B. Fenomena ini berpengaruh pada persediaan yang ada di toko. Informasi *purchase dependence* antara dua *item* atau *itemset* dapat digunakan untuk membuat kebijakan dalam manajemen persediaan, khususnya pada saat dilakukan penambahan stok (*replenishment*).

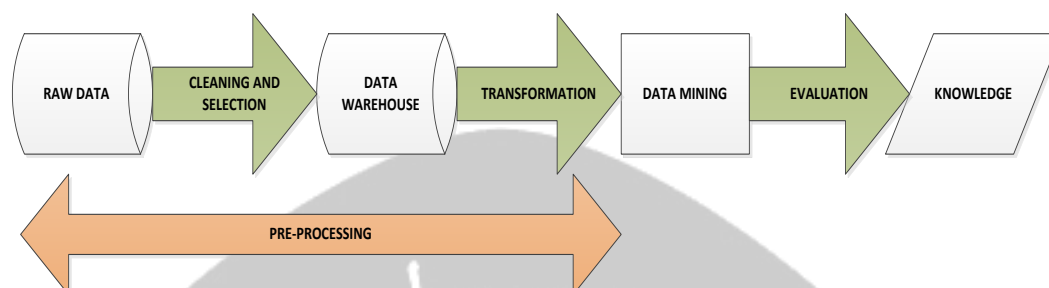
2.2.3. Data Mining

Dalam menghadapi fenomena *purchase dependence*, perlu diketahui *item* yang tergolong *purchase dependence item*. Informasi *purchase dependence item* dapat diketahui dengan melakukan penggalian data transaksi atau disebut *data mining*.

Menurut Han dan Kamber (2011), secara sederhana *data mining* mengacu pada kata "*mining*" atau berarti mengekstrak informasi dari data yang bervolume besar. Kata "*mining*" sendiri adalah istilah yang menggambarkan proses pencarian bagian kecil informasi yang berharga. Pada era teknologi serba canggih saat ini, jumlah informasi pada jalannya suatu bisnis bisa mencapai volume yang besar. *Data mining* merupakan suatu langkah yang diperlukan pada proses pencarian informasi yang penting. *Data mining* dapat diterapkan untuk berbagai macam data, salah satunya adalah data transaksi. Data transaksi adalah data yang mencakup catatan-catatan gambaran transaksi yang pernah dilakukan. Sistem *data mining* pada data transaksi dapat mengidentifikasi kombinasi *item* yang sering dibeli bersamaan atau sering disebut juga dengan istilah *market basket data analysis*.

Istilah "*data mining*" merupakan istilah yang sekarang ini lebih sering digunakan dibandingkan dengan istilah *Knowledge Discovery from Data* (KDD), walaupun

keduanya memiliki arti yang sama. Tahap dari *Knowledge Discovery* dapat dilihat pada Gambar 2.1.



Gambar 2.1. Tahap Pencarian Informasi dari Data

Pada Gambar 2.1 dipaparkan tahap dari proses knowledge discovery dari data, yakni terdapat tahap pre-processing data, tahap data mining, dan tahap evaluasi hasil. Tahap pre-processing sendiri memiliki tahap pembersihan dan penyaringan, serta tahap transformasi data. Hasil dari *knowledge discovery* adalah suatu informasi atau pengetahuan dari data yang dibutuhkan oleh pengguna.

a. Tahap *pre-processing* data

Pada tahap ini terdapat tahap pembersihan dan penyaringan, serta tahap transformasi data. Tahap penyaringan data dilakukan untuk menghilangkan data yang tidak digunakan. Menurut Santosa (2007), sebelum menggunakan data dengan metode atau teknik dari data mining, dilakukan *pre-processing* terhadap data. *Pre-processing* bermanfaat untuk mengurangi waktu pada saat komputasi. *Pre-processing* dapat membuat nilai data menjadi lebih kecil tanpa mengubah informasi.

b. Tahap *data mining*

Menurut Han dan Kamber (2011), *data mining* merupakan sebuah proses dimana sebuah metode diterapkan untuk mengekstrak pola data dari sejumlah data mentah. Menurut Santosa (2007), *data mining* adalah suatu kegiatan menemukan keteraturan, pola, atau hubungan dalam set data yang berukuran besar. Keluaran dari *data mining* ini bisa dipakai untuk memperbaiki pengambilan keputusan di masa depan.

c. Tahap evaluasi pola data

Setelah mendapatkan hasil dari *data mining*, selanjutnya hasil dievaluasi dengan mengidentifikasi hasil pola data tersebut benar merepresentasikan informasi sesuai dengan pengukuran yang dibuat.

2.2.4. Metode Association Rules dengan Algoritma Apriori

Association rules adalah teknik *data mining* untuk menemukan aturan asosiatif antara kombinasi *item*. Metode *data mining* ini adalah metode yang dapat memberi pola data keterkaitan untuk mengidentifikasi *purchase dependence item*. Terdapat dua tahap dasar dari metode Association Rules, yaitu:

a. Analisa pola frekuensi tinggi

Tahap ini mencari kombinasi *item* yang memenuhi syarat minimum dari nilai *support*. Dalam penelitian Gunadi dan Sensuse (2015) disebutkan bahwa nilai *support* merupakan ukuran untuk menunjukkan persentase atau tingkat dominasi permintaan *item* maupun *item-set* terhadap keseluruhan data transaksi. Sedangkan hubungan yang terjadi pada 2 *item* adalah $(A \rightarrow B) = P(A \cap B)$, yakni besar dominasi *item* A dibeli bersama dengan *item* B, atau *item* B dibeli bersama *item* A pada suatu kumpulan data transaksi. Nilai *support* sebuah *item* diperoleh dari persamaan 2.1.

$$P(A) = \frac{\Sigma \text{Transaksi mengandung A}}{\Sigma \text{Transaksi}} \quad (2.1)$$

Nilai *support* sebuah dua *item* diperoleh dari persamaan 2.2.

$$P(A \cap B) = \frac{\Sigma \text{Transaksi mengandung A dan B}}{\Sigma \text{Transaksi}} \quad (2.2)$$

b. Pembentukan aturan asosiatif

Setelah menemukan pola frekuensi tinggi, kemudian dicari aturan asosiatif yang memenuhi syarat minimum untuk *confidence* dengan menghitung nilai *confidence*. Menurut Santosa (2007), *confidence* adalah perbandingan antara transaksi yang mengandung *item antecedent* dan *consequent* dengan transaksi yang mengandung *item antecedent*. Istilah *antecedent* untuk mewakili bagian “jika” dan *consequent* untuk mewakili bagian “maka”. Rumus mencari nilai *confidence* terdapat pada persamaan 2.3.

$$P(B|A) = \frac{\Sigma \text{Transaksi mengandung antecedent dan consequent}}{\Sigma \text{Transaksi mengandung antecedent}} \quad (2.3)$$

Algoritma apriori adalah adalah algoritma yang digunakan untuk menemukan pola frekuensi tinggi dan dapat memberikan tingkat keyakinan yang lebih tinggi dibanding algoritma lainnya (Gunadi dan Sensuse, 2012). Berikut ini adalah langkah-langkah dalam algoritma apriori:

a. Pembentukan kandidat *itemset*.

Hasil dari tahap ini adalah terbentuknya kandidat *k-itemset* dari kombinasi $(k-1)$ -*itemset* iterasi sebelumnya. Ciri dari algoritma apriori adalah kandidat *k-itemset* yang tidak termasuk dalam pola frekuensi tinggi dengan panjang $k-1$ dihilangkan.

b. Penghitungan *support* dari tiap kandidat *k-itemset*.

Nilai *support* dari tiap kandidat *k-itemset* didapatkan dengan menghitung transaksi yang mengandung *item* dalam kandidat *k-itemset* tersebut.

c. Tetapkan pola frekuensi tinggi.

Pola frekuensi tinggi dapat ditetapkan dengan syarat kandidat *k-itemset* memiliki nilai *support* lebih besar dari minimum *support*.

d. Bila tidak terdapat pola frekuensi tinggi baru maka langkah dihentikan. Bila terdapat pola frekuensi tinggi baru, maka *k* ditambah satu dan kembali ke langkah awal.

Menurut Santosa (2007), cara lain untuk menguji kekuatan aturan asosiasi adalah dengan membandingkannya dengan nilai benchmark, yakni nilai yang mengasumsikan *item* dari *consequent* dalam suatu transaksi *independen* dengan kejadian dari *antecedent* dari suatu aturan asosiasi. Atau bisa dikatakan bahwa *item antecedent* dan *consequent* saling *independen*. Dalam keadaan *independen*, nilai *support* dinyatakan dalam Persamaan 2.4.

$$P(\textit{antecedent dan consequent}) = P(\textit{antecedent}) * P(\textit{consequent}) \quad (2.4)$$

Confidence benchmark dapat dinyatakan dalam Persamaan 2.5.

$$\frac{P(\textit{antecedent}) * P(\textit{consequent})}{P(\textit{antecedent})} = P(\textit{consequent}) \quad (2.5)$$

Nilai estimasi dari *confidence benchmark* dihitung dari data suatu rules yakni dengan Persamaan 2.6.

$$\textit{Confidence benchmark} = \frac{\textit{jumlah transaksi dengan item dalam consequent}}{\textit{jumlah transaksi dalam database}} \quad (2.6)$$

Kemudian dibandingkan nilai *confidence* suatu rules tersebut dengan nilai *confidence benchmark*-nya. Hasil rasio tersebut dinamakan lift rasio. Sehingga nilai lift rasio dapat diartikan sebagai perbandingan antara nilai *confidence* suatu aturan dengan *confidence* dimana diasumsikan *consequent* dan *antecedent* saling *independen*. Nilai rasio lebih dari satu menunjukkan bahwa adanya manfaat dari aturan tersebut. Jika semakin tinggi nilainya, kekuatan asosiasi semakin besar.

$$\textit{Lift rasio} = \frac{\textit{confidence}}{\textit{benchmark confidence}} \quad (2.7)$$

2.2.5. Program Tanagra 1.4.50

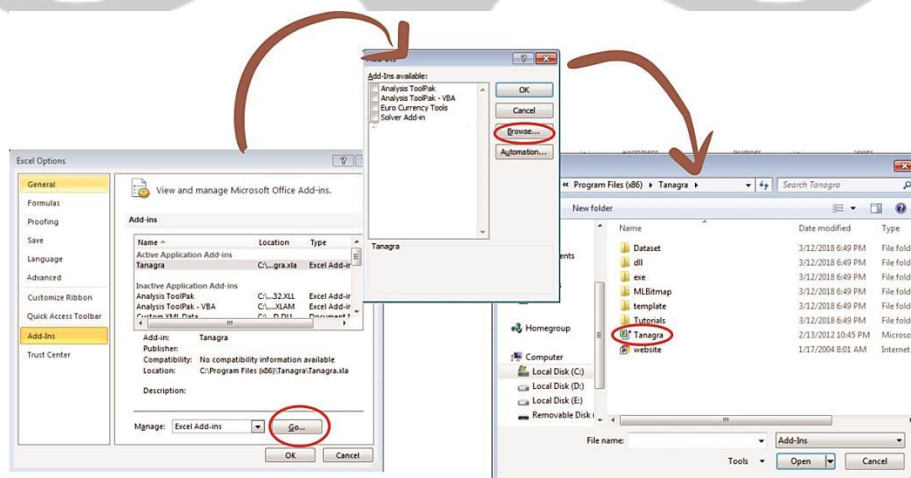
Data mining dapat dilakukan dengan bantuan *software* untuk mempersingkat waktu kalkulasi agar lebih cepat dalam menemukan pola data. *Software* yang digunakan adalah program Tanagra 1.4.50. Program Tanagra 1.4.50 adalah program *data mining* yang dikembangkan di negara Perancis dan dirilis pada tahun 2004. Program ini bebas dari biaya apapun dan bisa didapatkan dari situs aslinya. Program ini memiliki banyak komponen untuk menjalankan berbagai metode dari *data mining*.



Gambar 2.2. Logo Program Tanagra

Salah satu kelebihan dari program Tanagra adalah *dataset* yang dibutuhkan bisa dalam bentuk tabel pada *Microsoft Excel*. Namun diperlukan untuk meng-*install Add-In* Tanagra ke dalam *Microsoft Excel* terlebih dahulu. Selain itu, harus memastikan program Tanagra telah di-*install* terlebih dahulu. Berikut ini adalah cara untuk meng-*install Add-In* Tanagra pada *Microsoft Excel*.

- Pada *Microsoft Excel* klik *File* kemudian pilih *Options*, setelah itu akan muncul window *Excel Windows*. Kemudian pilih pada bagian *Add-In*.
- Pada Menu *Add-In*, dibagian bawah window terdapat *button Go*. Setelah dipilih maka akan muncul *window Add-Ins*.
- Pada window *Add-Ins*, pilih *button Browse* dan "tanagra.xla" yang terdapat pada folder program yang telah diinstall sebelumnya. Lalu pilih *OK*. *Add-Ins* Tanagra siap untuk digunakan. Langkah-langkah cara meng-*install Add-Ins* Tanagra dapat dilihat pada Gambar 2.3



Gambar 2.3. Langkah meng-*install Add-In* Program Tanagra

Penggunaan Program Tanagra dengan metode *Association Rules* memerlukan dataset pada *Microsoft Excel* berupa tabel tabular biner. Berikut ini adalah cara menggunakan Program Tanagra untuk metode *Association Rules*.

- a. Menyorot seluruh dataset kemudian memilih *Add-In Tanagra* dan pilih *Excecute*.
- b. Setelah itu secara otomatis Program Tanagra akan terbuka dan menampilkan deskripsi dari *dataset* yang ada.
- c. Melakukan definisi status atau menentukan *attribute* yang digunakan. *Attribute* yang dimaksud dalam metode ini adalah nama item yang digunakan. Jika button *define status* dipilih maka akan muncul *window Define attributes statuses*. Maka dari itu seluruh nama *item* dipilih untuk dijadikan input. Lalu klik OK.
- d. Pada bagian bawah Program Tanagra terdapat kotak *Components* dimana berisi metode-metode pada data mining. Karena ingin mencari *rules*, maka dipilih bagian *Association* dan memilih algoritma yang diinginkan. Dimisalkan disini menggunakan algoritma A priori.
- e. Pada tulisan A priori yang di klik kanan kemudian pilih Parameter. Maka akan muncul *window Association Rule parameter* dimana berisi parameter-parameter yang digunakan untuk menentukan *rules* nantinya.
- f. Setelah itu klik kanan pada tulisan A priori dan pilih *Excecute*. Lalu untuk menampilkan hasil pilih *View*. Maka hasil dari *rules* akan ditampilkan.

2.2.6. Klasifikasi ABC

Dalam memperkuat pentingnya informasi dari *data mining* untuk menghadapi fenomena *purchase dependence*, dibutuhkan bukti dari observasi atau penggambaran keadaan langsung dari suatu retail yang bersangkutan. Penggambaran kelas dari item dapat memperkuat informasi *data mining* untuk diketahui oleh pihak retail. Klasifikasi ABC dikemukakan oleh H.F. Dickie pada awal tahun 1950-an. Teknik ini digunakan untuk mengidentifikasi dan mengendalikan item-item persediaan yang penting. Menurut Yamit (2003), sistem klasifikasi ABC merupakan suatu prosedur sederhana dalam nilai rupiah penjualan. Klasifikasi sistem ABC merupakan petunjuk bagi perusahaan dalam memberikan prioritas pengawasan persediaan. Berikut ini adalah kriteria dari masing-masing kelas dalam analisis ABC:

- a. Kelas A, kelas item yang memiliki nilai volume penjualan yang tinggi. Persediaan untuk item yang termasuk kelas ini memerlukan perhatian tinggi dalam pengadaannya karena termasuk item krusial pada kelangsungan usaha.
- b. Kelas B, kelas item dengan nilai volume penjualan yang menengah. Pada kelas ini diperlukan perhatian yang moderat.
- c. Kelas C, kelas item yang memiliki nilai volume penjualan relatif rendah, bernilai sekitar 10% dari total persediaan. Pengendalian yang sederhana dan jarang dilakukan.

Langkah-langkah yang dilakukan pada klasifikasi ABC ini adalah sebagai berikut.

- a. Menentukan volume dalam nilai uang (rupiah). Rumus volume penjualan didapatkan dengan rumus sebagai berikut.

$$\text{Volume penjualan} = \text{volume (dalam unit)} \times \text{biaya per unit (rupiah)} \quad (2.4)$$

- b. Mengurutkan *item* persediaan berdasarkan volume rupiah dari yang terbesar nilainya ke yang terkecil.
- c. Menentukan volume rupiah kumulatif.
- d. Menentukan persentase kumulatif.

Rumus persentase kumulatif dapat dilihat pada persamaan 2.5.

$$\% \text{ Kumulatif} = \frac{\text{Volume dalam nilai uang per unit}}{\sum \text{Volume dalam nilai uang per unit}} \quad (2.8)$$

- e. Klasifikasikan ke dalam kelas A, B, dan C secara berturut-turut masing-masing sebesar kurang lebih 70%, 20%, dan 10% dari atas.

Menurut Heizer dan Render (2005), analisis ABC membagi keseluruhan item persediaan menjadi tiga kelompok berdasarkan volume tahunan dalam jumlah uang. Item pada kelas A adalah item dengan volume dolar tahunan yang tinggi. Item pada kelas A sekitar 15% dari total persediaan barang dengan 70% hingga 80% dari total volume tahunan dolar. Kelas B adalah kelas untuk item persediaan dengan volume dolar menengah. Item ini sekitar 30% dari barang persediaan dengan 15% hingga 25% dari nilai total. Item pada kelas C adalah item yang memiliki volume dolar tahunan rendah, yakni 5% dari volume dolar tahunan dan sekitar 55% dari total barang persediaan.

2.2.7. *Moving Average Price*

Dalam perhitungan klasifikasi ABC dibutuhkan data satu harga jual dan volume penjualan. Apabila harga jual dari *item* mengalami fluktuasi, maka diperlukan metode untuk menghasilkan satu harga. Metode tersebut adalah *Moving*

Average Price. Hasil dari metode *Moving Average Price* adalah satu nilai harga beli yang kemudian ditambah dengan *mark-up*.

Moving Average Price adalah metode *price control* yang diterapkan pada program SAP(program atau *software Enterprise Resource Planning* yang membantu perusahaan membantu dan merencanakan kegiatan operasional). Terdapat dua metode untuk mengontrol harga, yakni metode *Moving Average Price* dan metode *Standard Price*. *Standard Price* merupakan evaluasi pada material yang ada pada persediaan dalam harga yang selalu pasti atau tetap pada suatu periode tertentu tanpa mempertimbangkan stok baru yang ditambahkan dengan harga yang berbeda dari harga sebelumnya. Sedangkan metode *Moving Average Price* merupakan metode yang menentukan nilai dari stok total berdasarkan nilai stok lama dan nilai stok baru.

Perhitungan dari *Moving Average Price* biasanya digunakan untuk *raw material* dan *External Purchases*(pembelian dari pihak luar). Metode ini juga dapat memberikan suatu nilai harga untuk item stok lama dengan stok baru yang memiliki harga yang berbeda. Terdapat beberapa rumus yang digunakan dalam melakukan perhitungan *Moving Average Price*. Data yang dibutuhkan dalam perhitungan adalah:

- a. Jumlah item terbeli (*quantity receipt*)
- b. Harga beli item (*per price unit receipt*)
- c. Jumlah item terpakai atau terjual (*goods issue quantity*)
- d. Jumlah stok lama (*opening stock*)

$$\text{New stock} = \text{Opening Stock} + \text{Quantity Receipt} + \text{Goods Issue Quantity} \quad (2.9)$$

$$\text{Receipt Value} = \text{Quantity Receipt} \times \text{Per price unit receipt} \quad (2.10)$$

$$\text{New value} = \text{Old value} + \text{Receipt Value} \quad (2.11)$$

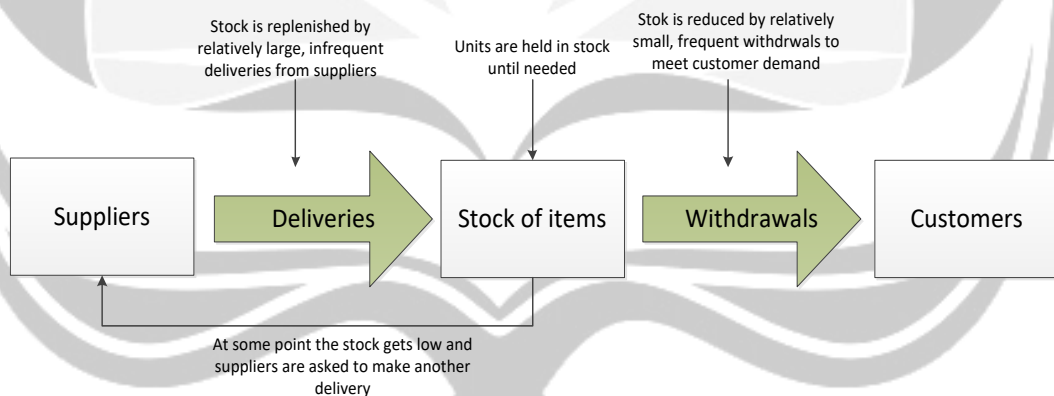
$$\text{Moving Average Price} = \frac{\text{New Value}}{\text{New stock}} \quad (2.12)$$

2.2.8. Stok dan Inventori

Penggambaran *demand* dilakukan untuk menegaskan manfaat informasi dari *data mining* agar perlu diketahui oleh retail. Penggambaran tersebut perlu perhitungan untuk menggambarkan stok dari inventori pada retail. Menurut Waters (2003), stok adalah sesuatu yang terdiri dari barang dan material yang disimpan oleh sebuah perusahaan yang akan digunakan untuk kebutuhan masa depan. Sedangkan istilah '*inventory*' merupakan daftar atau kumpulan dari barang-barang yang diadakan dalam stok. Suatu 'item' merupakan suatu jenis

produk yang disimpan dalam stok, dan merupakan salah satu masukan(*entry*) dalam suatu inventori. Stok memiliki bentuk yang berbeda-beda, ada stok yang *tangible* dan ada stok yang tidak jelas. Stok *tangible* dapat dilihat misalnya pada toko yang penuh dengan barang atau gudang yang penuh dengan barang jadi. Stok yang kurang jelas seperti misalnya stok pada penjualan pulsa, stok bangku tersisa pada bioskop, dan lain-lain.

Stok memiliki suatu siklus yang terbentuk dari supplier, perusahaan, dan terhubung pada customer. Stok terbentuk apabila suatu perusahaan membutuhkan material yang tidak langsung digunakan. Umumnya suatu barang yang sudah sampai dari supplier akan disimpan dalam stok hingga saatnya dibutuhkan. Penggambaran stok akan lebih mudah jika dispesifikan pada suatu operasi, misalnya stok pada *supermarket*. Barang yang sampai pada *supermarket* dari *supplier* selanjutnya akan dicek dan ditempatkan dalam rak. Kemudian barang tersebut akan berada pada rak hingga *customer* membelinya. Pada suatu saat stok akan berkurang, sehingga supermarket akan mengadakan pengiriman lagi (Waters, 2003). Gambaran dari siklus stok tersebut dapat dilihat pada Gambar 2.4.



Gambar 2.4. Siklus Stok pada Supermarket