

Digital Platform Demand Forecasting dengan Konsep Pembelajaran Mandiri di Industri Farmasi dan Makanan Ringan

M. Ali Fathoni¹, Agus Darmawan²

Departemen Teknik Mesin dan Industri, Universitas Gadjah Mada, Yogyakarta, Indonesia

¹malifathoni1992@mail.ugm.ac.id, ²agusd@ugm.ac.id

Abstrak- Pada industri manufaktur peranan *supply chain mangement* sangat vital untuk mendukung keberlangsungan perusahaan/bisnis dan untuk mengoptimalkan *revenue/profit* yang didapatkan oleh perusahaan. *Supply chain planning* mengambil peran yang sangat penting dalam kegiatan *supply chain management* terutama pada *demand planning* karena *demand planning* ini adalah tahap awal perencanaan pada *supply chain planning*, semakin akurat perencanaan maka *efficiency* dari aktivitas *supply chain* akan meningkat. Urgensi dari *demand planning* ini bertambah ketika diterapkan pada industri yang mempunyai karakteristik berbeda satu dengan yang lain seperti industri farmasi (volume kecil dan jenisnya banyak) dan industri makanan ringan (volume besar, jenis sedikit dan selera pasar variatif). Saat ini industri manufaktur sudah semakin banyak menggunakan *digital tools* sebagai *decision support system* (DSS) untuk proses *demand forecasting*, namun cakupan dari DSS ini masih sangat terbatas pada alat bantu hitung saja dengan pilihan *forecasting model* yang sangat terbatas dan *digital tools* ini belum sepenuhnya membantu dalam pengambilan sebuah keputusan atau *decision support system*. Hal ini bertolak belakang dengan kondisi pada dunia akademis yang intens pada penelitian di bidang *forecasting* dan *machine learning*, banyak sekali model-model baru dengan akurasi yang lebih baik. Oleh karena itu pada penelitian ini akan disajikan desain *digital platform framework* sebagai dasar *decision support system* untuk keperluan *demand forecasting* dengan konsep pembelajaran mandiri pada industri farmasi dan makanan ringan.

Kata kunci : *supply chain planning, demand forecasting, decision support system, machine learning, framework*

I. PENDAHULUAN

Pada industri manufaktur peranan *supply chain mangement* sangat vital untuk mendukung keberlangsungan perusahaan/bisnis dan untuk mengoptimalkan *revenue/profit* yang didapatkan oleh perusahaan. Beberapa perusahaan besar di dunia telah fokus dalam peningkatan efisiensi dan efektivitas *supply chain planning* diantaranya : Perusahaan “PepsiCo” menurut laporan “Business Wire” tahun 2018 pendapatan tahunan pada tahun 2017 telah meningkat 2.4% dikarenakan peningkatan efisiensi dalam rantai pasok dan *demand planning*, “Unilever” berdasarkan *annual report* pada tahun 2020 mencatat pertumbuhan pendapatan sebesar 1.9% dari peningkatan efisiensi rantai pasok termasuk *demand planning* yang lebih baik, “Nestle” berdasarkan *annual report* tahun 2019 mencatat pertumbuhan pendapatan sebesar 3.5% yang sebagian besar didorong oleh perbaikan *demand planning* dan rantai pasok mereka, “Coca-Cola Company” berdasarkan *annual report* tahun 2018 mencatat pertumbuhan pendapatan sebesar 5% yang sebagian besar didukung oleh inisiatif untuk meningkatkan efisiensi operasional dan *demand planning* mereka.

Demand planning merupakan salah satu komponen dari *supply chain planning* yang terdiri : *demand planning/forecasting; inventory planning; production planning; distribution planning; capacity & resource planning*. *Demand planning* dinilai paling beresiko dan memiliki dampak besar terhadap *supply chain planning* dibandingkan dengan komponen lainnya. *Demand planning* di industri manufaktur banyak digunakan/diintegrasikan dengan *inventory, cash flow, workforce planning, capacity planning, production planning, promotion planning* dan penetapan target penjualan [1]. Akurasi dari *demand planning* ini dapat dioptimalkan dengan membuat model *forecast* yang sesuai dengan kondisi dan karakter dari suatu produk/barang yang akan diproduksi. Welber dan Chrono [2] telah melakukan survei terhadap 200 perusahaan di UK (14 diantaranya adalah perusahaan *pharmaceutical*), dari survey tersebut 82.1% dari mereka menggunakan model *forecast* sederhana yaitu *moving average, single exponential smoothing*, dan *naïve* dengan kegiatan *forecasting* dilakukan secara manual, sedangkan Zhu *et al* [1] melakukan survey terhadap 5 perusahaan *pharmaceutical* di China dari industri manufaktur tersebut menggunakan *forecasting tools* yang didalamnya hanya menggunakan 1-3 model *forecast* tertentu saja, yaitu *moving average, exponential smoothing, linear regression* untuk diterapkan ke semua SKU (*Stock Keeping Unit*) yang ada. Justifikasi dari *expert* pada *demand forecasting* juga sebenarnya diperlukan agar proses *demand planning* lebih akurat, sekitar 10-30% dari industri menggunakan *human judgement* tersebut [1].

Pada sisi lain, di dunia akademi, penelitian-penelitian untuk menghasilkan akurasi model *forecast* yang baik masih sangat diminati dan telah banyak dilakukan sampai sekarang, bahkan menurut Li *et al* [6] beberapa peneliti telah mengembangkan *forecasting* ini dengan beberapa kombinasi tidak hanya *statistical model* (ARIMA, *vector autoregressive, bayesian*) saja namun juga menggunakan *intelligent model*, dan *hybrid model*, misal : *shallow & deep neural network* [10], *fuzzy neural network* [11], *hybrid model of RF-XGB-LR* [12], HATT-CNN-BiLSTM [13]. *Big data analytics* juga banyak digunakan untuk mengkombinasikan data penjualan sebelumnya dengan data-data selain data penjualan, misal : *customer review, customer behaviour* [7], *market sentiment* [9]. Penelitian-penelitian tersebut sebagian besar masih berupa komparasi dan pengujian hipotesis saja, masih sangat sedikit yang sudah ditanam dalam sebuah *decision support system*.


Karakteristik dari industri farmasi dan industri makanan cukup banyak perbedaan, industri farmasi mempunyai volume penjualan yang relatif kecil namun mempunyai *margin* yang besar, jenis dari produk yang dihasilkan pun beragam : dilihat dari *segment* (obat *oral, obat non oral, obat injeksi, multivitamin, dll*), dilihat dari bentuk (*solid, semi-solid, gel, syrup liquid, suspension liquid, effervescent dll*), dilihat dari kemasan (*strip, blister, sachet, botol, tube dll*). Pada industri farmasi bahan baku yang digunakan sebagian besar (+/- 80%) adalah barang impor dan mempunyai variasi yang banyak (1 SKU bisa terdiri dari 40 bahan baku & bahan

kemas pada *bill of material*-nya) dan penanganan kualitasnya pun berbeda dibandingkan bahan baku & bahan kemas lain. Sedangkan industri makanan umumnya mempunyai volume yang jauh lebih tinggi dari industri farmasi namun *margin*-nya jauh lebih kecil, selain itu jenisnya hanya terbatas tidak sebanyak industri farmasi, seperti biskuit, wafer, kembang gula (permen). Visual kemasan dari produk-produk di industri makanan (bentuk, warna, gambar dan ukuran) sangat variatif dan lebih cepat pergantiannya. Sehingga pada industri makanan bahan kemas menjadi aspek yang sangat dikendalikan, sedangkan pada bahan baku meskipun sebagian besar bisa didapatkan secara *local* (tidak impor) dan *non-dedicated* (bisa digunakan antar SKU) namun umur dari bahan bahan tersebut cukup pendek (misal : tepung terigu, gula, minyak dll). Karakter dari industri farmasi dan makanan yang unik dan cukup berbeda itu yang menjadi tantangan bagi industri (khususnya dalam kegiatan SCM), karena jika produk-produk yang mempunyai perbedaan karakter tersebut saat *demand forecasting* tidak dilakukan dengan tepat dan baik (1 model *forecasting* untuk semua SKU) maka akan mengakibatkan *inventory* pada bahan baku & bahan kemas serta *inventory finished goods* bisa berlebih atau bahkan *stock out* sehingga berpotensi menimbulkan kerugian yang cukup besar dalam hal *disposal cost* dan *shortage cost*.

Demand Forecasting merupakan kegiatan/proses bisnis yang tidak hanya dilakukan/dijalankan 1 kali di awal perencanaan saja dan selanjutnya (di tahun-tahun berikutnya) tidak perlu dilakukan lagi, namun *demand forecasting* ini perlu dilakukan terus menerus pada setiap periode, *time horizon* dari *forecasting* tergantung dari maksud dan tujuannya, umumnya *time horizon* dengan jangka waktu panjang (*long term*) > 5 tahun digunakan untuk *strategic supply chain planning*, *medium term* 1-5 tahun digunakan untuk *financial forecasting & budgeting planning* sedangkan *short term* < 1 tahun digunakan untuk *supply chain operation planning* [3]. *Short term demand forecasting* yang digunakan antar perusahaan berbeda-beda tergantung kebijakan masing-masing perusahaan, contohnya pada hasil survei yang dilakukan oleh Zhu *et al* [1] dari 5 perusahaan *pharmaceutical time horizon forecasting* bervariasi mulai dari 3 bulan/12 minggu (3 perusahaan), 1 bulan/4 minggu (1 perusahaan) dan 1 minggu (1 perusahaan), pada periode tersebut *forecast* bersifat terkunci/tetap/tidak bisa dirubah namun pada periode selanjutnya *forecast* bisa dirubah berdasarkan evaluasi dari *time horizon* sebelumnya. Hal ini menunjukkan bahwa *demand forecasting* ini bersifat sangat dinamis dan kontinyu (terus menerus), sehingga jika ada sebuah *platform* yang mampu untuk melakukan *forecast* terus menerus berdasarkan *actual sales* yang masuk tiap periodenya dan mampu untuk melakukan *self learning* sehingga akurasi *forecast* bisa lebih baik dengan menggunakan data-data yang terkumpul maka akan sangat memudahkan *user* di Industri. Zhu *et al* [1] juga menyebutkan bahwa meskipun 5 perusahaan *pharmaceutical* yang dijadikan obyek survei sudah menggunakan *forecasting tools* namun didalamnya belum tersedia model *machine learning* pada pilihan/variasi model *forecast*-nya dan *self learning* pada algoritmanya, hasil *forecast* akan didapatkan ketika *user* memasukkan data *actual sales* dan memilih model apa yang digunakan (*moving average/ exponential smoothing/ linear regression*).

II. METODE PENELITIAN

Pada penelitian ini data yang digunakan adalah data *historical actual sales* dari beberapa SKU di PT. XYZ yang merupakan perusahaan manufaktur yang bergerak di penyediaan produk farmasi dan makanan ringan. SKU yang diambil sebagai studi kasus masing-masing 3 SKU untuk produk farmasi dan 3 SKU untuk produk makanan ringan, sedangkan model *forecasting* yang digunakan menggunakan 6 model *forecasting*. Alur penelitian yang digunakan ditunjukkan pada Gambar 1.



Gambar 1. Alur Penelitian

A. Desain Framework DSS

Pada *decision support system* dalam penelitian ini hanya fokus pada pembuatan *framework digital platform* untuk *demand forecasting*, sehingga *interface*, tampilan dan evaluasi dari *user interface* serta faktor kognitif dari *decision maker* tidak dibahas atau tidak diatur secara detail pada penelitian ini, hanya saja hasil performa dari *digital platform* ini akan ditampilkan pada hasil dan. Pembahasan.

B. Model Forecasting

Pada framework akan digunakan 5 jenis model forecasting yang cukup sederhana dan cukup banyak digunakan, 3 diantaranya merupakan *statistics time series model* yaitu *weighted moving average*, *holt's winter (triple exponential smoothing)*, *seasonal and trend decomposition using loess (STL)* dan 2 yang lainnya merupakan *machine learning model* yaitu : *ridge regression* dan *classification and regression tree (CART)*. Pemilihan 5 jenis model tersebut didasarkan pada pertimbangan : model tersebut sederhana (secara konsep dan perhitungan), model tersebut banyak digunakan (baik pada *forecasting tools* yang dipakai di berbagai industri maupun pada penelitian-penelitian sebagai model pembandingan), mempunyai minimal 1 parameter untuk optimasi (detail parameter akan dijelaskan pada sub bab selanjutnya) dan model-model tersebut tidak memerlukan data yang banyak untuk proses *fitting*. Semua model forecasting yang ditanamkan pada *digital platform* juga dilengkapi dengan *parameter optimization* menggunakan model *random search*.

C. Pemilihan Sampel SKU

Pemilihan SKU dilakukan tidak secara acak melainkan dipilih berdasarkan tipe produknya misal : NAN039, KOX001, TWB055, CHL024, DES001, ALO003. Kode tersebut merupakan kode SKU yang digunakan pada PT. XYZ namun tidak ditampilkan secara lengkap karena alasan *confidential* dan penulis menganggap penggalan kode tersebut sudah cukup unik dan sudah bisa untuk membedakan SKU satu dengan yang lain. Penjelasan detail tentang SKU ini akan ditampilkan pada sub bab selanjutnya/

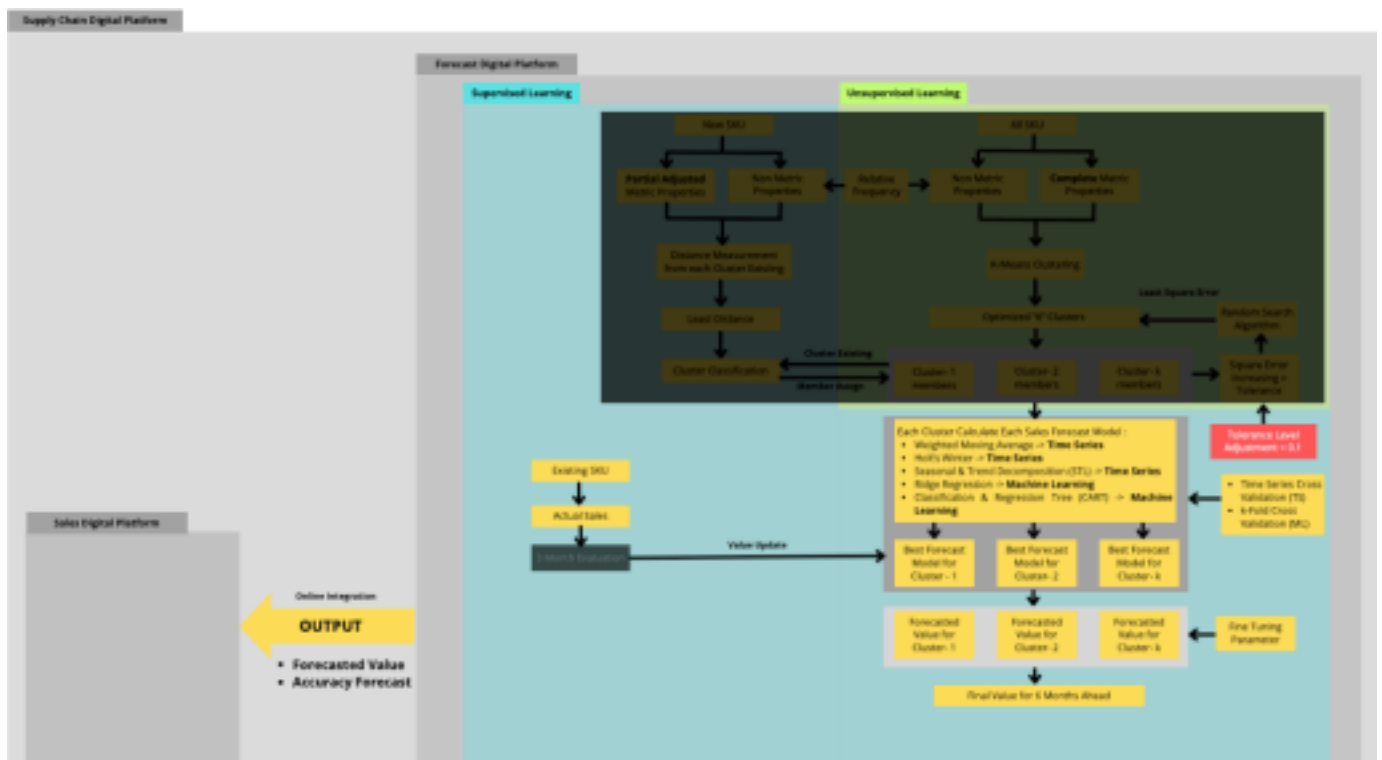
D. Rekomendasi Model Forecasting

Rekomendasi yang diberikan untuk masing-masing SKU dipilih berdasarkan *Mean Absolute Percentage Error (MAPE)* paling kecil dengan membandingkan kelima model *forecasting* yang ditanamkan pada *digital platform* beserta nilai parameter hasil optimasi. Penggunaan parameter evaluasi MAPE didasarkan pada kemudahan interpretasi dari parameter tersebut dibandingkan dengan parameter yang lain (misal AIC, BIC, MSE, wMAPE), kemudahan perhitungan dibandingkan yang lain dan kesesuaian dengan kebutuhan (jumlah SKU terbatas dan SKU tunggal/tidak dalam kluster).

III. HASIL DAN PEMBAHASAN

A. Pembuatan Desain Framework DSS

Desain framework yang dibuat didalamnya sudah memuat 5 model forecasting dan masing-masing model sudah dilengkapi dengan *parameter optimization* menggunakan *random search*, pada optimasi ini jumlah dan rentang parameter yang digunakan setiap model berbeda-beda, pada bab ini nanti akan langsung ditampilkan hasil akhirnya. Pada *framework* yang ditampilkan Gambar 2 terdapat kotak/blok warna hitam yang mana langkah dan tahap tersebut tidak termasuk dalam penelitian ini.



Gambar 2. Framework Digital Platform

B. Sampel Pengujian Framework

Sampel yang digunakan pada pengujian ini adalah sejumlah 6 SKU yang mana 3 SKU merupakan produk yang masuk ke dalam industri farmasi dan 3 SKU lainnya merupakan SKU yang masuk ke dalam industri makanan ringan, detail dari SKU tersebut dijelaskan pada Tabel 1, pada Tabel 1 *internal forecasting accuracy* didapatkan dari hasil *forecasting* internal PT. XYZ dengan

menggunakan metode yang selama bertahun-tahun dipakai yaitu *naïve* dan proses perhitungan menggunakan aplikasi *spreadsheet* dengan alur dan durasi yang sangat panjang (lebih dari 1 minggu).

Tabel 1. Detail Sampel dan Internal Forecasting

| Industri | SKU ID | SKU details | Internal Forecasting Accuracy |
|----------------|--------|---|-------------------------------|
| Farmasi | ALO003 | Obat <i>oral</i> berbentuk <i>solid</i> | 74.67% |
| Farmasi | DES001 | Obat <i>non oral</i> berbentuk <i>semisolid</i> | 84.57% |
| Farmasi | KOX001 | Obat <i>oral</i> berbentuk kapsul | 82.54% |
| Makanan Ringan | NAN039 | Kembang gula (<i>hard candy</i>) | 82.14% |
| Makanan Ringan | CHL024 | Biskuit | 81.13% |
| Makanan Ringan | TWB055 | Krekers | 87.00% |

C. Pembuatan Model Forecasting

Model yang digunakan pada *framework* beserta parameternya ditampilkan pada Tabel 2.

Tabel 2. Detail Model Forecasting & Parameter

| Model Forecasting | Parameter |
|---|---|
| <i>Weighted Moving Average (WMA)</i> | <i>Window Size, Weight</i> |
| <i>Holt's Winter</i> | <i>Alpha, Beta, Gamma</i> |
| <i>Seasonal and Trend Decomposition using Loess (STL)</i> | <i>Period, Seasonal, Trend Slope</i> |
| <i>Ridge Regression</i> | <i>Alpha</i> |
| <i>Classification and Regression Tree (CART)</i> | <i>Maximum Depth, Minimum Samples Split, Minimum Samples Leaf</i> |

Weighted Moving Average merupakan model *forecasting* yang mempertimbangkan data periode-periode sebelumnya seperti halnya pada *simple moving average* namun dengan tambahan sistem pembobotan pada setiap periodenya, semakin tinggi bobotnya pada periode tertentu menandakan periode tersebut semakin dipertimbangkan, total dari pembobotan masing-masing periode ini maksimal adalah 1 dan periode yang digunakan (*windown size*) bervariasi mulai dari 3-12 periode.

Holt's Winter merupakan modifikasi dari *simple exponential smoothing*, model *forecasting* ini juga biasa disebut *triple exponential smoothing* karena model ini mempertimbangkan 3 aspek yaitu *level*, *trend* dan *seasonal* yang diwakili oleh parameter *alpha*, *beta* dan *gamma*. Parameter ini jika dilakukan optimasi akan mampu meningkatkan akurasi prediksi yang dihasilkan dari model dengan rentang parameter mulai 0-1.

Seasonal and Trend Decomposition using Loess (STL) merupakan model *forecasting* yang secara khusus digunakan untuk data yang memiliki *trend* dan *seasonal* karena prinsip kerja dari STL ini adalah menyaring *trend* dan *seasonal* dengan menggunakan teknik LOESS (*Locally Estimated Scatterplot Smoothing*) *regression*, LOESS ini sebenarnya adalah teknik *smoothing* dengan menggunakan parameter yang bisa dilakukan optimasi seperti *period*, *seasonal* dan *trend slope*.

Ridge Regression merupakan model *forecasting* yang masuk pada kategori *machine learning*, model ini tidak memerlukan

urutan data untuk melakukan *forecasting* seperti pada model *forecasting* menggunakan *statistics time series* model. *Ridge Regression* merupakan modifikasi dari *linear regression* dengan peruntukan untuk *forecasting* dengan jumlah data yang tidak banyak, pada model ini terdapat parameter yang digunakan untuk regularisasi sehingga bisa meningkatkan kualitas *fitting* pada model.

Classification and Regression Tree (CART) merupakan model *forecasting* hasil modifikasi dari *machine learning model* yang cukup terkenal yaitu pohon keputusan (*decision tree*), pada CART ini menggabungkan *Classification Tree* dan *Regression Tree*. Penggabungan model ini bertujuan untuk mengakomodasi lebih banyak tipe data yang digunakan untuk *forecasting* yaitu tipe data kategori dan tipe data numerik. CART mempunyai beberapa parameter yang dapat dioptimasi sehingga bisa menghasilkan akurasi prediksi yang lebih baik.

D. Rekomendasi Model Forecasting

Model *forecasting* yang ditanamkan pada *framework* dicari nilai akurasi *forecasting* yang optimal dengan melakukan *adjustment/ optimai* pada parameter menggunakan model *random search* dengan *objective function* adalah minimasi nilai MAPE, masing-masing SKU yang dimasukkan ke dalam *digital platform* akan diterapkan model satu per satu sampai dengan menemukan MAPE yang paling kecil. Hasil dari proses *forecasting* ini ditampilkan pada Tabel 3, sedangkan hasil rekomendasi model terbaik dan perbandingan dengan *internal forecasting* ditampilkan pada Tabel 4.

Tabel 3. Hasil Forecasting Per SKU

| SKU ID | MAPE | | | | |
|--------|--------|-------|--------|--------|--------|
| | WMA | HW | STL | RR | CART |
| ALO003 | 11.10% | 9.38% | 11.55% | 13.67% | 12.22% |

| SKU ID | MAPE | | | | |
|--------|--------|--------|--------|--------|--------|
| | WMA | HW | STL | RR | CART |
| DES001 | 5.74% | 7.68% | 8.12% | 11.09% | 9.89% |
| KOX001 | 3.72% | 17.8% | 17.59% | 23.98% | 21.77% |
| NAN039 | 15.86% | 11.82% | 11.94% | 13.75% | 13.89% |
| CHL024 | 13.12% | 15.68% | 20% | 58.86% | 24.69% |
| TWB055 | 9.36% | 10.76% | #N/A | 16.07% | 14.38% |

Tabel 4. Rekomendasi Model Forecasting

| SKU ID | MAPE Terbaik Digital Platform | MAPE Internal Forecasting | %Perubahan | Model Terbaik | Parameter Terbaik |
|--------|-------------------------------|---------------------------|------------|---------------|---|
| ALO003 | 9.38% | 25.33% | 62.85% | HW | Alpha : 0.035, Beta : 0.23, Gamma : 0.609 |
| DES001 | 5.74% | 15.43% | 62.80% | WMA | Window size : 5, W1 : 0.036, W2 : 0.099, W3 : 0.094, W4 : 0.0012, W5 : 0.77 |

| | | | | | |
|--------|--------|--------|--------|-----|---|
| KOX001 | 3.72% | 17.46% | 78.69% | WMA | Window size : 3, W1 : 0.101, W2 : 0.0242, W3 : 0.875 |
| NAN039 | 11.82% | 17.86% | 33.82% | HW | Alpha : 0.19, Beta : 0.51, Gamma : 0.021 |
| CHL024 | 13.12% | 18.87% | 30.47% | WMA | Window Size : 5, W1 : 0.038, W2 : 0.0013, W3 : 0.040, W4 : 0.013, W5 : 0.91 |
| TWB055 | 9.36% | 13.00% | 28% | WMA | Window Size : 3, W1 : 0.051, W2 : 0.031, W3 : 0.92 |

Hasil dari *digital platform* ini terlihat sangat efektif karena jika dilihat pada Tabel 4 menunjukkan bahwa MAPE yang dihasilkan oleh *digital platform* pada 6 sampel SKU jauh lebih kecil dibandingkan dengan MAPE *internal forecasting* yang telah dilakukan sebelumnya, bahkan angka perubahannya pun sangat meyakinkan yaitu mulai 28% s/d 78.69%.

Model *forecasting* yang terpilih menjadi model terbaik tidak semuanya sama untuk semua SKU meskipun yang paling banyak terpilih adalah WMA dan HW. Begitu juga dengan SKU yang mendapatkan rekomendasi model terbaik WMA ataupun HW pun masing-masing mempunyai parameter yang tidak sama (lihat parameter terbaik). Hal ini menunjukkan bahwa dengan SKU yang memiliki karakter berbeda-beda tidak bisa diterapkan model *forecasting* yang sama persis, misal kita uji cobakan beberapa SKU dipaksa menggunakan model dan parameter seperti SKU yang lain.

1. CHL024 jika menggunakan Window Size = 3 sama dengan KOX001 nilai MAPEnya akan menjadi 22.03% atau meningkat 67.9%.
2. ALO003 jika diterapkan model WMA sedangkan model terbaiknya adalah HW maka MAPE akan meningkat 18.3%
NAN039 jika diterapkan model WMA sedangkan model terbaiknya adalah HW maka akan meningkat 34.1%.

Perbedaan antara SKU industri farmasi dengan industri makanan belum tergambar secara jelas meskipun MAPE SKU dari industri farmasi memang relatif lebih kecil/rendah 45.1% dibandingkan SKU makanan ringan (MAPE Farmasi 6.28%, MAPE Makanan Ringan 11.43%). Namun hal ini perlu dilakukan penelitian lebih lanjut apakah temuan ini masih valid dengan seluruh SKU dilibatkan, pengujiannya bisa dengan sistem klustering atau menguji berdasar pertimbangan finansial lain (*sales value contribution, promotion cost, inventory cost, disposal cost* dll) atau pengujian pengaruh antara jenis industri/ karakter produk terhadap model *forecasting* yang direkomendasikan.

Jika dilihat dari proses *demand forecasting* antara sebelum yaitu menggunakan metode yang selama ini dipakai PT. XYZ (*naïve* model) dan menggunakan *digital platform* pada penelitian ini perbedaannya cukup besar, meskipun hal ini belum bisa dibandingkan secara setara karena durasi proses *demand forecasting* metode yang dipakai PT. XYZ untuk semua SKU (tidak hanya 6 sampel tersebut dan menggunakan 1 jenis forecasting) sedangkan waktu komputasi pada *digital platform* ini untuk 6 sampel 5 model forecasting hanya membutuhkan +/- 10 menit, namun secara cukup jelas bisa terlihat perbedaannya akan sangat signifikan (harus dibuktikan dengan penelitian lebih lanjut) dan secara dampaknya pun sudah terlihat jelas ada peningkatan akurasi 28% s/d 78.69%.

IV. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan yaitu pembuatan desain *framework digital platform demand forecasting* didapatkan kesimpulan sebagai berikut :

1. *Digital platform* terbukti berhasil sebagai *decision support system* dalam hal pemilihan model *forecasting* untuk masing-masing SKU (dibuktikan dengan pengujian alur *framework* menggunakan 6 sampel), dengan *platform* ini mampu meningkatkan akurasi *demand forecasting* sebesar 28% s/d 78.69%
2. SKU yang berbeda yang mana menunjukkan karakter produk yang berbeda terbukti memang tidak bisa diterapkan hanya 1 model untuk semua SKU (kondisi *existing* 1 model *forecasting* digunakan untuk semua SKU), efek dari memaksakan model dan parameter *forecasting* ini akan menurunkan akurasi sebesar 18.35% s/d 34.1%. Kombinasi dari 6 SKU tersebut mempunyai kontribusi sales 1% terhadap seluruh sales PT. XYZ sehingga penurunan akurasi s/d 34.1% akan berdampak cukup signifikan terhadap sales dari perusahaan.
3. Belum ada pengaruh yang pasti dan valid antara jenis industri/jenis produk terhadap akurasi *forecasting* dan model *forecasting* yang dipakai meskipun dari penelitian ini terlihat SKU produk farmasi mempunyai akurasi lebih tinggi 45.1% dibandingkan produk-produk makanan ringan.
4. Durasi proses *demand forecasting* terjadi penurunan yang sangat signifikan dibandingkan kondisi *existing* meskipun perlu diuji lebih lanjut dengan kondisi yang setara.
5. Jika akurasi *demand forecasting* ini dihubungkan dengan efek lain sesuai dengan gambaran yang disampaikan pada

pendahuluan misalnya pada *supply planning* maka dampaknya akan sangat besar, dari sisi *inventory* bahan baku & bahan kemas akan sangat efisien, begitu juga dengan *inventory* pada barang jadi (*finished goods*) sehingga potensi *disposal cost* bisa diturunkan. Kombinasi dari 6 SKU tersebut saat ini menyumbang 0.88% *disposal cost* dari *sales value*-nya yang termasuk kategori tinggi jika dibandingkan *benchmark* perusahaan sejenis, dengan peningkatan akurasi *demand forecasting* s/d 78.69% maka dampaknya akan cukup signifikan

V. KETERBATASAN & PENELITIAN SELANJUTNYA

Pada penelitian yang telah dilakukan masih sangat terbatas karena hanya menggunakan 6 SKU sebagai sampel, meskipun secara tujuan utama penelitian ini sudah terpenuhi yaitu desain *framework decision support system* (DSS). Sedangkan jika dilihat kondisi dari PT. XYZ saat ini SKU aktif yang dimiliki adalah lebih dari 400 SKU, maka untuk mendapatkan efek solusi yang lebih besar dan lebih nyata muncul beberapa diskusi untuk penelitian selanjutnya :

1. Apakah *framework* DSS ini masih cukup baik atau tidak dengan SKU sebanyak itu (lebih dari 400 SKU) ? 2. Apakah proses *forecasting* 1 per 1 cukup efektif (mudah dan cepat) dengan jumlah SKU sebanyak itu (lebih dari 400 SKU) ?
2. Apakah *framework* DSS ini bisa digunakan secara kontinyu karena seperti yang diketahui proses *demand forecasting* akan berlulang setiap periodenya?
3. Bagaimana perlakuan *framework* DSS ini dengan adanya data SKU baru yang ditambahkan? Apakah bisa langsung diterapkan pada *framework* DSS ini?
4. Apakah ada pengaruh antara jenis industri/ karakter produk dengan pemilihan model *forecasting* yang tepat (akurasi leih baik) ?

DAFTAR PUSTAKA

- [1] M. Weller and S. Crone, "Supply Chain Forecasting: Best Practices & Benchmarking Study," Lancaster Centre For Forecasting, 2012.
- [2] A. G. Cook, *Forecasting for the Pharmaceutical Industry Models for New Product and In-Market Forecasting and How to Use Them*, Gower Publishing Limited, 2016.
- [3] X. Zhu, A. Ninh, H. Zhao and Z. Liu, ""Demand Forecasting with Supply-Chain Information and Machine Learning: Evidence in the Pharmaceutical Industry",", *Production and Operation Management*, vol. 0, 2021. [4] X. Zhang and T. Kim, "A hybrid attention and time series network for enterprise sales forecasting under digital management and edge computing," *Journal of Cloud Computing: Advances, Systems and Applications*, vol. 12, no. 13, 2023. [5] C. Zhang, Y. X. Tian, Y. Liu and L. W. Fan, "Product sales forecasting using macroeconomic indicators and online reviews: a method combining prospect theory and sentiment analysis," *Soft Computing*, 2019.
- [6] C. Zhang, Y. X. Tian and Z. P. Fan, "Forecasting sales using online review and search engine data: A method based on PCA-DSFOA-BPNN," *International Journal of Forecasting*, vol. 38, no. 4, 2022.
- [7] S. M.-R. Vaghefinezhad, J. Razmi and F. Jolai, "A Novel Approach for Multi Product Demand Forecast Using Data Mining Techniques (Empirical Study: Carpet Industry)," *Advances in Industrial Engineering*, vol. 53, no. 4, 2021. [8] R. Rathipriya, A. A. A. Rahman, S. Dhamodharavadhani, A. Mero and G. Yoganandan, "Demand forecasting model for time-series pharmaceutical data using shallow and deep neural network model," *Neural Computing and Applications*, vol. 35, no. 3, 2022.
- [9] A. Mitra, A. Jain, A. Kishore and P. Kumar, "A Comparative Study of Demand Forecasting Models for a Multi-Channel Retail Company: A Novel Hybrid Machine Learning Approach," *Operations Research Forum*, vol. 3, no. 58, 2022. [10] G. Li, H. Wu and H. Yang, "A hybrid forecasting model of carbon emissions with optimized VMD and error correction," *Alexandria Engineering Journal*, vol. 81, 2023.
- [11] V. Ekambaram, K. Manglik, S. Mukherjee, S. S. K. Sajja, S. Dwivedi and V. Rakhyar, "Attention based Multi-Modal New Product Sales Time-series Forecasting," *Applied Data Science Track Paper*, 2020.
- [12] M. A. I. Arif, S. I. Sany, F. I. Nahin and A. S. A. Rabby, "Comparison Study: Product Demand Forecasting with Machine Learning for Shop," in *8th International Conference System Modeling and Advancement in Research Trends (SMART)*, Moradabad, India, 2019.
- [13] D. I. Ajiga, N. Leonardo, O. F. Asuzu, O. R. Owolabi, T. S. Tubokirifuruar and R. A. Adeleya, "AI-DRIVEN PREDICTIVE ANALYTICS IN RETAIL: A REVIEW OF EMERGING TRENDS AND CUSTOMER ENGAGEMENT STRATEGIES," *International Journal of Management & Entrepreneurship Research*, vol. 6, no. 2, 2024.