

## BAB 2

### TINJAUAN PUSTAKA

Bab 2 membahas penelitian-penelitian terdahulu yang dibagi ke dalam beberapa segmen, yaitu *voice of customer*, analisis sentimen dan *machine learning*, dan pemilihan ide. Selain itu Bab 2 juga membahas dasar teori yang digunakan dalam penelitian.

#### 2.1. Tinjauan Pustaka

Sub-bab ini akan membahas tentang penelitian-penelitian terdahulu mengenai pengembangan produk dan penggunaan *machine learning* dalam proses pengembangan produk.

##### 2.1.1. Pengembangan Produk

Pengembangan produk merupakan bagian vital untuk mempertahankan daya saing dari setiap organisasi. Melalui proses ini spesifikasi dan proses produksi suatu produk ditentukan dengan mempertimbangkan kebutuhan pasar, ketersediaan teknologi, dan strategi dari organisasi itu sendiri (Iakoch, 2019).

Tahapan-tahapan dalam melakukan pengembangan produk telah dikembangkan dalam penelitian-penelitian terdahulu. Cooper (1990) mengusulkan sebuah sistem *stage-gate* untuk pengembangan produk. Sistem ini membagi proses pengembangan produk ke dalam beberapa tahapan (*stage*) dimana di depan setiap tahapan terdapat sebuah gerbang (*gate*). Gerbang-gerbang ini berfungsi sebagai sebuah titik cek kontrol pada proses pengembangan produk. Terdapat lima tahapan pengembangan produk yang diusulkan, yaitu penilaian awal, persiapan investigasi secara detail, pengembangan/*development*, test dan validasi, produksi dan peluncuran produk. Kelima gerbang di depan tiap tahapan tersebut adalah penyaringan pertama, penyaringan kedua, keputusan untuk *business case*, *review* pasca pengembangan, dan analisis bisnis pra komersialisasi.

Ulrich & Eppinger (2015) mendefinisikan pengembangan produk sebagai serangkaian aktivitas yang dimulai dengan identifikasi peluang di pasar dan diakhiri dengan produksi, penjualan, dan pengiriman suatu produk. Mereka membagi proses pengembangan produk ke dalam beberapa tahap, yaitu: perencanaan, pengembangan konsep, desain tingkat sistem, desain detail, pengujian dan penyempurnaan, dan produksi. Tahapan-tahapan ini dibagi ke dalam beberapa tahapan kecil lainnya. Sebagai contoh, tahapan pengembangan

konsep dibagi ke dalam tahapan mengidentifikasi kebutuhan pelanggan, menentukan spesifikasi produk, memunculkan konsep produk, dan melakukan tes terhadap konsep. Tahap konseptual desain berhubungan dengan bagaimana kebutuhan diidentifikasi dan perumusan konsep desain produk. Prototipe dibuat untuk menguji konsep yang diajukan, dan peluncuran produk berhubungan dengan proses komersialisasi produk.

Pembagian proses pengembangan produk ke dalam beberapa tahapan juga diikuti oleh Kaulio (1998). Dalam penelitiannya mengenai keterlibatan pelanggan dalam proses pengembangan produk, Kaulio membagi proses pengembangan produk ke dalam lima fase. Fase-fase tersebut adalah spesifikasi, pengembangan konsep, desain yang mendetail, prototipe, dan produk akhir. Büyükzkan & Arsenyan (2012) mengajukan tahapan-tahapan serupa dalam penelitiannya mengenai pengembangan produk kolaboratif. Pienaar dkk. (2019) menggunakan model *stage gate* dimana pengembangan produk terdiri dari empat “gerbang” dan empat tahapan, yaitu tahapan eksplorasi dimana ide dikonseptualisasi, tahapan penilaian dimana peluang didefinisi, tahapan riset dimana pengembangan teknologi pilot/pertama dilakukan, dan tahapan persiapan implementasi dimana dilakukan percobaan komersialisasi teknologi pilot yang telah dibuat.

Dari penelitian-penelitian yang telah disebutkan di atas, terdapat berbagai macam tahapan pengembangan produk baru. Menurut Carter (2015) tidak ada satu tahapan pengembangan produk terbaik yang dapat mengungguli tahapan pengembangan produk lainnya. Secara umum tahapan pengembangan produk dapat dikelompokkan menjadi tiga kelompok besar, yaitu desain konseptual, prototipe, dan peluncuran produk. Pengelompokan tahapan-tahapan yang diajukan pada penelitian sebelumnya dapat dikelompokkan menjadi tiga kelompok besar tahapan pengembangan produk dapat dilihat dalam Tabel 2.1.

**Tabel 2.1. Pengelompokan Tahapan Pengembangan Produk**

Penulis	Tahapan Pengembangan Produk		
	Conceptual design	Prototype	Product launch
Cooper (1990)	<ul style="list-style-type: none"> <li>- Preliminary assessment</li> <li>- Detailed investigation (business case) preparation</li> </ul>	<ul style="list-style-type: none"> <li>- Development</li> <li>- Testing &amp; validation</li> </ul>	<ul style="list-style-type: none"> <li>- Full production &amp; market launch</li> </ul>
Ulrich & Eppinger (2015)	<ul style="list-style-type: none"> <li>- Planning</li> <li>- Concept development</li> <li>- System-level design</li> </ul>	<ul style="list-style-type: none"> <li>- Detail design</li> <li>- Testing and refinement</li> </ul>	<ul style="list-style-type: none"> <li>- Production ramp-ups</li> </ul>
Kaulio (1998)	<ul style="list-style-type: none"> <li>- Specification</li> <li>- Concept development</li> </ul>	<ul style="list-style-type: none"> <li>- Detailed design</li> <li>- Prototyping</li> </ul>	<ul style="list-style-type: none"> <li>- Final product</li> </ul>
Büyükcikan & Arsenyan (2012)	<ul style="list-style-type: none"> <li>- Conceptual design</li> </ul>	<ul style="list-style-type: none"> <li>- Product development</li> <li>- Prototype</li> </ul>	<ul style="list-style-type: none"> <li>- Manufacturing</li> <li>- Product launch</li> </ul>
Pienaar dkk. (2019)	<ul style="list-style-type: none"> <li>- Explore</li> <li>- Assess</li> </ul>	<ul style="list-style-type: none"> <li>- Research</li> </ul>	<ul style="list-style-type: none"> <li>- Prepare for implementation</li> </ul>

### **2.1.2. Voice of Customer**

*Voice of customer* (VoC) merupakan sebuah sumber daya yang penting bagi perusahaan. VoC berisi ekspektasi-ekspektasi serta kebutuhan-kebutuhan konsumen terhadap produk, dan ekspektasi ini membantu perusahaan-perusahaan dalam proses pengembangan produk atau jasa mereka (Aguwa dkk., 2017). Metode-metode yang dilakukan untuk mengumpulkan VoC dapat berupa survey, interview, *focus group discussion*, dan metode lainnya (Kapucugil Ikiz & Özdağoğlu, 2015; Šperkova, 2019). Dengan berkembangnya teknologi, *platform-platform* untuk mendengarkan VoC juga semakin bertambah. *Platform* media sosial dan *e-commerce* seperti *Facebook*, *Twitter*, *Reddit*, *Youtube*, *Amazon*, dan *Tokopedia* digunakan untuk mengumpulkan data berupa post, *review*, dan komentar dari pengguna. *Feedback* yang diberikan pelanggan secara sukarela pada platform-platform tersebut menjadi faktor penting dalam fase pengembangan dan desain produk (Park dkk., 2018).

Selain itu, data yang diambil dari media sosial ini digunakan untuk berbagai macam tujuan, salah satu diantaranya untuk memprediksi tingkat kepopuleran perusahaan berdasarkan reaksi konsumen di media sosial (Park & Alenezi, 2018). Gupta & Sebastian (2018) melihat performa suatu produk di pasar berdasarkan penilaian dan ulasan yang diberikan oleh pengguna, dan Zhou dkk. (2016) membandingkan perilaku konsumen ketika berbelanja secara daring.

Salah satu hambatan yang dihadapi dalam mengolah data yang didapat dari platform daring seperti media sosial dan *e-commerce* adalah jumlah data yang besar. Mendapatkan informasi yang berguna dan bermakna dari data tersebut menjadi suatu tantangan tersendiri. Penggunaan *text mining* membantu menjembatani proses ini. Jeong & Yoon (2016) menggunakan *text mining* untuk mendapatkan VoC dan menemukan peluang pengembangan pada produk ponsel pintar. J. Park dkk. (2018) menggunakan analisis sentimen untuk menemukan fitur yang lebih dipentingkan dalam perbaikan desain ban.

### **2.1.3 Analisis Sentimen dan *Machine Learning* (ML)**

Analisis sentimen dikenal juga dengan beberapa istilah lain seperti *opinion mining*, *sentimen mining*, *opinion extraction* merupakan sebuah proses mendeteksi serta mengklasifikasi polaritas kontekstual dari teks (Micu dkk., 2017).

Secara garis besar, terdapat dua macam pendekatan untuk melakukan analisis sentimen, yaitu analisis sentimen berbasis ML dan analisis sentimen berbasis

leksikon/kamus. Analisis sentimen berbasis ML seringkali melibatkan sebuah model untuk menetapkan label pada data berdasarkan data yang telah dilatih pada model tersebut. Sementara analisis sentimen berbasis leksikon menggunakan kata-kata yang telah ditentukan terlebih dahulu, dimana tiap kata dikaitkan dengan sentimen tertentu (Gonçalves dkk., 2013).

Beberapa metode yang sering digunakan untuk melakukan analisis sentimen berbasis ML adalah metode klasifikasi seperti Support Vector Machine (SVM) dan Naïve Bayes (Kolchyna dkk., 2015). Metode-metode lain seperti Maximum Entropy (ME), Logistic Regression, Apriori, Random Forest, juga digunakan di beberapa penelitian lainnya (Ahmad dkk., 2017; Samuel dkk., 2020). Ren dkk. (2018) menggunakan analisis sentimen dan *Support Vector Machine* (SVM) untuk memprediksi arah pergerakan pasar saham. Analisis sentimen digunakan untuk mengukur psikologis investor dan kemudian menggabungkannya dengan data pasar saham untuk meramal arah pergerakan pasar saham tersebut dengan tingkat akurasi sampai dengan 89,93%. Penelitian lain menggunakan SVM untuk menentukan persepsi pengguna terhadap fitur-fitur dari ulasan beberapa *merk* laptop (Devi dkk., 2016). Bazarganigilani (2011) menambahkan konsep berbasis ontologi dalam algoritma Naïve Bayes untuk mendeteksi e-mail *phising*, dan mendapatkan tingkat akurasi sebesar 94,87% ketika menentukan apakah suatu e-mail adalah *spam* atau tidak.

Samuel dkk. (2020) melakukan analisa sentimen terhadap tingkat ketakutan masyarakat terhadap Coronavirus melalui *platform* Twitter, serta membandingkan tingkat akurasi dari klasifikasi menggunakan metode Naïve Bayes dan Logistic Regression. Hasil temuan menyatakan bahwa Naïve Bayes memberikan akurasi tinggi untuk klasifikasi *tweet* dengan jumlah karakter sedikit, dan *Logistic Regression* memberikan hasil yang lebih baik dari *Naïve Bayes* ketika mengklasifikasikan *tweet* dengan jumlah karakter banyak. Klasifier *Naïve Bayes* digunakan oleh Troussas dkk. (2013) bersamaan dengan klasifier *Rocchio* dan *Perception* untuk menentukan sentimen pada status di *platform* Facebook, sehingga aplikasi belajar bahasa yang digunakan dapat menjadi adaptif dan menyesuaikan metode belajar dengan apa yang pengguna rasakan saat itu. Temuan yang didapat menunjukkan *Naïve Bayes* memiliki presisi paling tinggi, namun tingkat recall yang lebih rendah dari *Rocchio*. Tabel 2.2. menunjukkan rangkuman penggunaan metode *machine learning* dalam melakukan analisis sentimen di berbagai *platform*.

**Tabel 2.2. Penelitian Tentang Penggunaan *Machine Learning* untuk Analisis Sentimen**

No	Peneliti & Tahun	Judul	Metode	Platform	Temuan
1.	Ren dkk. (2018)	<i>Forecasting Stock Market Movement Direction Using Sentiment Analysis and Support Vector Machine</i>	SVM	Portal berita	Mampu memprediksi arah pergerakan pasar saham dengan tingkat akurasi 89,93%
2.	Devi dkk. (2016)	<i>A Feature-Based Approach for Sentiment Analysis by Using Support Vector Machine</i>	SVM	Twitter	Dapat menentukan persepsi pengguna terhadap fitur-fitur produk
3.	Bazarganigilani (2011)	<i>Phishing E-Mail Detection Using Ontology Concept and Naïve Bayes Algorithm.</i>	<i>Naïve Bayes with ontology concept</i>	E-mail	Tingkat akurasi klasifikasi e-mail spam meningkat sampai dengan 94,87%
5.	Samuel dkk. (2020)	<i>COVID-19 public sentiment insights and machine learning for tweets classification</i>	<i>Naïve Bayes dan Logistic Regression</i>	Twitter	<i>Naïve Bayes</i> memberikan tingkat akurasi tinggi ketika mengklasifikasi tweet pendek, dan <i>Logistic Regression</i> sebaliknya.
6.	Troussas dkk. (2013)	<i>Sentiment analysis of Facebook statuses using Naive Bayes classifier for language learning.</i>	<i>Naïve Bayes, Rocchio, Perception</i>	Facebook	<i>Naïve Bayes</i> memiliki tingkat akurasi tertinggi, namun tingkat recall lebih rendah dari Rocchio

Penggunaan analisis sentimen menggunakan ML dalam tahapan pengembangan produk telah dilakukan oleh Ireland & Liu (2018) dalam penelitian mereka

mengenai aplikasi data *analytics* untuk desain produk. Dalam penelitian tersebut, analisis sentiment digunakan untuk mendapatkan wawasan yang dapat digunakan desainer untuk mengevaluasi tingkat kepentingan fitur-fitur produk, sehingga desainer dapat menangkap kebutuhan pelanggan dengan lebih akurat. Ireland & Liu (2018) mengusulkan penggunaan *feature-sentiment pairs* (FSP) dimana fitur dari suatu produk yang didapat dari *review* pelanggan dipasangkan dengan sentimen *review* tersebut. Namun, fitur yang dimaksud berupa kata benda yang tercantum di dalam teks *review* pelanggan, misalnya “cooler/useful”. Walaupun diketahui bahwa sentimen dari *cooler* bernada positif karena kata *useful*, aspek dari *cooler* yang membuat *cooler* tersebut menjadi *useful* tidak ditampilkan. Kurangnya detail dari FSP membuat wawasan (*insight*) yang didapat menjadi terbatas.

#### **2.1.4. Machine Learning Dalam Kategorisasi Kebutuhan**

Seperti yang telah disebutkan sebelumnya, Shabestari dkk. (2019) telah merangkum penelitian-penelitian terdahulu yang berkaitan dengan penggunaan ML dalam tahap awal pengembangan produk. Dari penelitian tersebut, terdapat lima puluh satu penelitian yang menggunakan metode ML, baik metode *supervised* maupun *unsupervised learning*. Pada tahapan kategorisasi kebutuhan terdapat dua belas penelitian dimana sebelas dari dua belas penelitian menggunakan metode *unsupervised learning* dan satu penelitian yang menggunakan metode *supervised learning*.

Aguwa dkk. (2017) menggunakan teknik klustering untuk mengelompokkan kata kunci yang berperan penting terhadap kualitas dari *review* pelanggan. Logika *fuzzy* kemudian digabungkan dengan model klustering tersebut untuk menangkap esensi utama dari *review* pelanggan, sehingga pemenuhan kebutuhan pelanggan terhadap produk atau jasa dapat ditingkatkan.

Lee & Bradlow (2011) melakukan *text mining* untuk mendapatkan pro dan kontra dari *review* pelanggan. Proses klustering dilakukan pada atribut pro dan kontra untuk membagi kata-kata ke dalam kategori khusus. Proses tersebut dapat mengungkap posisi produk dibandingkan dengan kompetitor atau produk serupa dan menyorot atribut-atribut produk yang menonjol di mata pelanggan.

Abad dkk. (2017) mengklasifikasikan kebutuhan pelanggan ke dalam dua kategori, yaitu kebutuhan fungsional/*functional requirements* (FR) dan kebutuhan non-fungsional/*non-functional requirements* (NFR). Dari penelitian didapatkan bahwa

klasifikasi NFR ke dalam sub-kategori seperti kegunaan, ketersediaan, dan performa secara otomatis dapat ditingkatkan dengan menggunakan ML. Beberapa algoritma ML untuk pengelompokkan, baik *supervised* maupun *unsupervised learning*, dibandingkan dan disimpulkan bahwa Naïve Bayes memberikan hasil akurasi tertinggi dibanding dengan metode lainnya.

## 2.2. Penelitian Sekarang

Seperti yang telah disebutkan dalam bagian 2.1.1., secara garis besar terdapat tiga tahapan utama dalam pengembangan produk, yaitu desain konseptual, prototipe, dan peluncuran produk. Berdasarkan literatur-literatur yang telah dibahas pada bagian-bagian sebelumnya, penggunaan *text mining* dan ML telah digunakan dalam berbagai fase pengembangan produk, termasuk di dalam tahapan awal pengembangan produk. Namun, penelitian dengan menggunakan metode *supervised learning* dalam tahapan kategorisasi kebutuhan belum banyak dilakukan. Sedangkan, menurut Edwards dkk. (2021) serta hasil dari penelitian Abad dkk. (2017), klasifikasi menggunakan teknik *supervised learning* cenderung lebih akurat apabila dibandingkan dengan teknik *unsupervised learning*.

Penelitian sekarang mencoba memenuhi celah/*gap* yang ada dengan melakukan teknik *supervised learning* pada tahap kategorisasi kebutuhan. Kategorisasi kebutuhan dilakukan dengan melakukan pelabelan pada *review* pelanggan terhadap suatu produk. Label yang diberikan berkaitan dengan kriteria yang menjadi pertimbangan dalam mendesain suatu produk dan sentimen pelanggan mengenai produk tersebut yang ditulis dalam *review*. Analisis sentimen digunakan untuk mengidentifikasi kelemahan dari produk yang di-*review* pelanggan (Zhang dkk., 2012), maupun mengukur kepuasan pelanggan (Kang & Park, 2014). Tujuan penggunaan klasifikasi *multi-label* dalam tahapan kategorisasi kebutuhan adalah untuk membantu pembuat keputusan dalam mengkategorisasikan kebutuhan pelanggan berdasarkan salah satu aspek dari suatu produk dan persepsi pelanggan terhadap aspek tersebut. Sehingga, hal ini akan membantu dalam tahapan pembuatan konsep desain produk yang dapat memenuhi kebutuhan/keinginan pelanggan.

Kategorisasi kebutuhan dengan menggunakan klasifikasi *multi-label* dilakukan dengan menggunakan ilustrasi kasus pada *review* pelanggan pakaian wanita di suatu platform *e-commerce*. Data *review* pelanggan tersebut menggunakan data dari Agarap (2018) yang diunduh melalui [www.kaggle.com](http://www.kaggle.com). Proses yang pertama



kali dilakukan adalah melabeli *review* pelanggan dengan label-label kriteria dan sentimen. Setelah data dilabeli, selanjutnya adalah melakukan eksplorasi data dan melihat 'kesiapan' data sebelum analisis dilakukan. Pra-prosesing data dilakukan untuk mengolah data agar layak untuk dilakukan analisis. Analisis data dilakukan dengan menggunakan teknik klasifikasi teks yang umum digunakan seperti SVM (Kang & Park, 2014; Povoda, 2016; Wibowo Haryanto & Kholid Mawardi, 2018), Naïve Bayes (Hadi dkk., 2018; Jiang dkk., 2013; Singh dkk., 2019; Tan dkk., 2009; Troussas dkk., 2013), dan *Logistic Regression* (Pranckevičius & Marcinkevičius, 2017; Shah dkk., 2020; Wang dkk., 2017).

Model dari teknik klasifikasi dengan performa terbaik dipilih sebagai model klasifier acuan. *Review* dari pelanggan dijadikan *input*, kemudian label dari tiap *review* akan diprediksi berdasarkan model yang telah dipilih. Kebutuhan pelanggan akan dikelompokkan berdasarkan sentimen dan mengacu pada kriteria-kriteria produk tertentu. Pengelompokan kebutuhan pelanggan selanjutnya akan dijadikan acuan dalam penentuan arah pengembangan produk.

### 2.3. Dasar Teori

Bagian ini akan menjelaskan mengenai algoritma-algoritma yang digunakan dalam model prediksi.

#### 2.3.1. Naïve Bayes

Klasifier Naïve Bayes merupakan sebuah teknik klasifikasi yang didasarkan pada theorem Bayes. Penelitian ini menggunakan metode Complement Naïve Bayes, karena menurut Seref & Bostanci (2019) Complement Naïve Bayes memberikan hasil yang lebih baik dibandingkan Naïve Bayes untuk klasifikasi teks. Klasifier Complement Naïve Bayes dinyatakan oleh Jiang dkk. (2013) sebagai berikut:

$$c_{\text{CNB}}(d) = \arg \max_{c \in C} \left[ -\log P(\bar{c}) - \sum_{i=1}^m f_i \log P(w_i | \bar{c}) \right] \quad (2.1)$$

Dimana  $\bar{c}$  merupakan komplemen dari kelas  $c$  (semua kelas kecuali kelas  $c$ ),  $m$  adalah jumlah kata,  $w_i$  adalah kata ke- $i$  yang muncul dalam dokumen  $d$ ,  $f_i$  adalah frekuensi kata  $w_i$  yang muncul dalam dokumen  $d$ . Probabilitas prior  $P(\bar{c})$  dan probabilitas kondisional  $P(w_i | \bar{c})$  dihitung dengan menggunakan persamaan (4) dan (5) berikut ini secara berturut-turut.

$$P(\bar{c}) = \frac{\sum_{j=1}^n \delta(c_j, \bar{c}) + 1}{n + l} \quad (2.2)$$

$$P(w_i | \bar{c}) = \frac{\sum_{j=1}^n f_{ji} \delta(c_j, \bar{c}) + 1}{\sum_{i=1}^m \sum_{j=1}^n f_{ji} \delta(c_j, \bar{c}) + m} \quad (2.3)$$

Dimana  $n$  adalah jumlah dokumen *training*,  $l$  adalah jumlah kelas,  $c_j$  adalah label kelas dari dokumen *training* ke- $j$ ,  $f_{ji}$  adalah frekuensi kata  $w_i$  pada dokumen *training* ke- $j$  dan  $\delta$  adalah sebuah fungsi binary yang bernilai 1 apabila parameternya identical dan bernilai 0 apabila tidak.

### 2.3.2. Logistic Regression

Model Logistic Regression dinyatakan oleh Shah dkk. (2020) sebagai berikut:

$$\text{logit}(S) = b_0 + b_1 M_1 + b_2 M_2 + \dots + b_k M_k \quad (2.4)$$

Dimana  $S$  adalah probabilitas dari fitur yang dicari,  $M$  adalah nilai predictor, dan  $b$  adalah nilai intersep dari model. Dalam klasifikasi teks, model Logistic Regression mengenali sebuah vektor yang mengandung variabel dan kemudian mengevaluasi koefisien untuk setiap variabel input dan memprediksi kelas teks dalam bentuk vektor kata.

### 2.3.3. Support Vector Machine (SVM)

SVM adalah sebuah algoritma yang mengubah data ke dalam dimensi yang lebih tinggi dimana *hyperplane* yang memisahkan data dapat dicari menggunakan tupel yang disebut vektor support (Han dkk., 2011). Han dkk. (2011) mengatakan walaupun SVM merupakan metode klasifikasi yang akurat, SVM memiliki waktu proses yang lamban ketika dihadapkan dengan jumlah data yang besar. Untuk menghindari hal tersebut, digunakan Linear SVM yang memiliki waktu proses lebih cepat (Pedregosa dkk., 2011). Model Linear SVM dinyatakan Pedregosa dkk. (2011) sebagai berikut.

$$\min_{w,b} \frac{1}{2} w^T w + C \sum_{i=1} \max(0, 1 - y_i (w^T \phi(x_i) + b)) \quad (2.5)$$