

BAB II TINJAUAN PUSTAKA DAN DASAR TEORI

2.1. Tinjauan Pustaka

Tinjauan pustaka dilakukan pada penelitian yang membahas konsep retail berkelanjutan dan aktivitas manajemen persediaan khususnya pada sektor retail. Gambar 2.1 dan Gambar 2.2 menunjukkan *mind map* penelitian yang terkumpul pada tahap tinjauan pustaka. Tabel 2.1, Tabel 2.2, dan Tabel 2.3 menunjukkan klasifikasi kontribusi penelitian sebelumnya dan penelitian yang dilakukan.

2.1.1. Retail Berkelanjutan Berkaitan dengan Isu Energi

Saat ini, sektor retail mulai menerapkan berbagai praktik "hijau," seperti manajemen limbah, pengurangan limbah plastik makanan, efisiensi energi dan air, perlindungan biodiversitas, efisiensi transportasi, dan kepatuhan terhadap standar atau sertifikasi yang ada, seperti yang dilakukan oleh sektor retail makanan di Romania (Grosu, 2023). Strategi dekarbonisasi dalam retail, seperti penetapan tujuan energi, investasi pada rantai pasok yang efisien, operasi retail yang ramah lingkungan serta desain bangunan yang berfokus pada efisiensi energi, dengan tujuan mengelola masalah perubahan iklim semakin relevan semenjak adanya Perjanjian Paris (*Paris Agreement*) (Ferreira dkk., 2019). Beberapa peneliti melakukan penelitian untuk mengembangkan metode penilaian dan evaluasi bangunan pada sektor retail, seperti yang dilakukan oleh Gulliford dkk. (2022) yang menilai performa emisi dan biaya pada retail, Gabriel Filho dkk. (2023) yang menerapkan metode evaluasi energi PROCEL pada suatu retail agribisnis, Ferreira dkk. (2019) yang mengembangkan metode *Building Sustainability Assessment* (BSA) untuk bangunan retail. Bangunan memang merupakan salah satu penyumbang utama gas rumah kaca, sehingga sangat penting untuk mengurangi konsumsinya. Tetapi, tidak mudah untuk melakukan renovasi terhadap bangunan untuk menghemat energi karena adanya kesulitan untuk mengukur seberapa besar energi yang dihemat. Severinsen & Myrland (2022) menjawab masalah tersebut dengan mengembangkan metode statistik untuk mengestimasi penghematan energi yang didapatkan dari renovasi bangunan retail. Penelitian lain yang berkaitan dengan isu energi pada bangunan retail adalah tentang kebijakan pengelolaan energi pada bangunan, seperti mengurangi dan mengalihkan konsumsi energi puncak atau untuk memenuhi perubahan

kebutuhan energi dengan menggunakan baterai (Barchi dkk., 2019; Saabit dkk., 2021). Terdapat juga penelitian yang mengembangkan strategi untuk mengoptimalkan kebijakan energi yang melibatkan lebih dari satu bangunan dengan cara melakukan distribusi atau pembagian energi antar bangunan (Syed & Hachem, 2019; Syed & Hachem-Vermette, 2023). Selanjutnya penelitian yang berhubungan dengan bangunan pada retail adalah tentang penggunaan sumber energi terbarukan, seperti penggunaan *fuel cell*, bimetana, dan panel *photovoltaic* (Accurso dkk., 2021; Acha dkk., 2020; Ayoub dkk., 2020).

Isu energi pada retail tidak hanya berkaitan dengan bangunan, melainkan juga berkaitan dengan aktivitas pada retail. Salah satu aktivitas pada retail adalah transportasi untuk memindahkan logistik dari suatu tempat ke tempat lain. Aktivitas transportasi tentunya akan menghasilkan dampak terhadap lingkungan, seperti emisi karbon, dan harus diminimalkan. Permasalahan rute kendaraan (*vehicle routing problem*) merupakan salah satu masalah optimasi yang dapat digunakan untuk mengurangi dampak lingkungan pada aktivitas transportasi dengan menentukan rute terbaik. Bas & Ozkok (2023) melakukan pengembangan metode *Linear Fractional Vehicle Routing Problem* (LFVRP) yang mempertimbangkan multi tujuan, yaitu beban dan biaya untuk meminimasi konsumsi bahan bakar dengan tetap mempertahankan beban maksimal. Perhatian terhadap aktivitas transportasi pada retail semakin meningkat dengan adanya perkembangan perdagangan secara elektronik (*e-commerce*) dengan meningkatnya jumlah pengiriman ke rumah. Heshmati dkk. (2019) dan Muñoz-Villamizar dkk. (2022) menjawab permasalahan tersebut dengan mengevaluasi waktu pengiriman dengan tujuan meningkatkan efisiensi, menghemat biaya, dan mengurangi emisi karbon. Usaha dekarbonisasi pada aktivitas transportasi juga dilakukan dengan mempertimbangkan penggunaan sumber energi baru pada moda transportasi (Winkler dkk., 2022). Selain aktivitas transportasi, emisi karbon juga dapat disebabkan oleh aktivitas yang berkaitan dengan pengelolaan persediaan. Sebagai contoh Ahmad dkk. (2023) mengembangkan model berbasis *Economic Order Quantity* dengan pembelajaran efek kerusakan pada item ramah lingkungan dalam kondisi inflasi dan pembiayaan kredit untuk meminimalkan total biaya. Aktivitas pada retail juga erat kaitannya dengan rantai pasok antara produsen dengan retail. Kuiti dkk. (2019) menyatakan bahwa dengan melakukan kolaborasi antara produsen dengan retail serta rantai pasokan yang terpusat cenderung menghasilkan inisiatif ramah lingkungan yang lebih baik.

Selanjutnya, terdapat isu energi yang berkaitan dengan penggunaan sistem pendingin pada retail. Penelitian dalam bidang ini salah satunya dilakukan untuk mengganti sistem pendingin dengan refrigeran yang lebih ramah lingkungan atau dengan *Global Warming Potential* (GWP) yang lebih rendah untuk mengurangi emisi karbon (Expósito-Carrillo dkk., 2021; Hart dkk., 2020). Selain itu, penelitian juga dilakukan terhadap mekanisme pada mesin pendingin, seperti implementasi sistem pendingin CO₂ berbasis ejektor ganda (Sengupta & Sankar Dasgupta, 2023) serta penggunaan sistem pendingin berbasis air untuk menggantikan pendinginan udara (Efstratiadi dkk., 2019). Pada saat bekerja, suatu sistem pendingin juga akan menghasilkan panas. Maouris dkk. (2020) memanfaatkan panas yang dihasilkan oleh sistem pendingin sebagai pemanas ruangan untuk menggantikan sistem pemanas ruangan konvensional yang menggunakan tungku gas.

2.1.2. Manajemen Persediaan pada Sektor Retail

Hingga saat ini, terdapat tiga bagian besar penelitian dalam hal manajemen persediaan pada sektor retail, yaitu berkaitan dengan peramalan sebagai dasar manajemen persediaan, sistem pemantauan persediaan, dan kebijakan pemesanan atau *replenishment*.

a. Peramalan sebagai dasar manajemen persediaan

Peramalan permintaan memegang peran penting pada pengendalian persediaan dan rantai pasok serta pada pengambilan keputusan sebuah organisasi (Benhamida dkk., 2021). Proses peramalan dapat menjadi kompleks ketika berhadapan pada pola permintaan yang tidak teratur (Tian dkk., 2021), seperti permintaan yang berjedat dan dengan ketidakteraturan tinggi (*lumpy demand*) atau ketidakteraturan rendah (*intermittent demand*) (Sarlo dkk., 2023; Syntetos & Boylan, 2005). Peramalan yang salah dapat menyebabkan kelebihan atau kekurangan persediaan yang dapat meningkatkan biaya persediaan (Gustriansyah dkk., 2022). Tian dkk. (2021) melakukan pengembangan metode peramalan untuk mengatasi permintaan berjedat dengan menggunakan *Markov-combined method* (MCM). Model MCM yang dikembangkan dinilai lebih akurat dalam meramal permintaan berjedat dibanding metode peramalan klasik, seperti *single exponential smoothing* (SES), *Syntetos-Boylan approximation* (SBA), dan *Croston* (CR). Model peramalan untuk permintaan bersifat *lumpy* dan berjedat juga dikembangkan oleh Sarlo dkk. (2023) dengan menggunakan *score-driven model*. Peramalan permintaan juga menjadi tugas yang menantang, terutama pada suatu

jaringan retail karena adanya integrasi pesanan dari toko elektronik dan fisik serta adanya *third party logistic* (3PL) yang bertanggung jawab terhadap penerimaan, penyimpanan, hingga pengiriman barang dari pemasok ke retail. Lalou dkk. (2020) memaparkan bahwa *data analytic* dapat mendukung proses pengambilan keputusan 3PL untuk melakukan *replenishment* jaringan toko. Penelitian tersebut menggunakan bahasa pemrograman “R” untuk membandingkan berbagai metode peramalan dan mengidentifikasi metode yang menghasilkan kesalahan terkecil.

b. Sistem pemantauan persediaan

Pengelolaan ketersediaan produk pada etalase dan persediaan secara efisien juga merupakan masalah kunci untuk mencapai kepuasan pelanggan dan untuk mengurangi risiko kehilangan keuntungan (Milella dkk., 2020). Kehabisan produk (*stockout*) yang disebabkan oleh kesalahan dalam pengelolaan stok secara manual dan kesalahan penempatan produk pada rak merupakan salah satu tantangan utama dalam sektor industri retail (Sikkandhar dkk., 2023). Selain risiko *stockout*, pemeriksaan fisik pada etalase secara konvensional bersifat padat karya dan seringkali menghasilkan penilaian yang tidak dapat diandalkan (Milella dkk., 2020). Untuk mengatasi permasalahan tersebut, beberapa retail telah mengadopsi teknologi *automatic identification and data capture* (AIDC) dengan berbagai tingkat keberhasilan (Atkins dkk., 2021). *Radio frequency identification* (RFID) merupakan salah satu contoh teknologi yang dapat digunakan untuk mengeliminasi ketidakakuratan pada persediaan pada rantai pasok retail (Tao dkk., 2022). RFID dan *Internet of Things* (IoT) diharapkan memainkan peran penting dalam pemenuhan kebutuhan pelanggan pada rantai pasok (Tan & Sidhu, 2022). Seiring perkembangan teknologi, RFID juga dapat dimanfaatkan untuk mengembangkan sistem penghitungan persediaan otonom dengan tingkat akurasi yang cukup tinggi (Casamayor-Pujol dkk., 2020) dan robot otonom yang dapat melakukan pengambilan stok yang lebih akurat dan efisien daripada metode tradisional dengan operator manusia dengan RFID *handheld reader* (Morenza-Cinos dkk., 2019). Selain penggunaan teknologi RFID sebagai sarana untuk meningkatkan visibilitas persediaan, terdapat juga penggunaan *smart-textile sensor* yang memanfaatkan *piezoresistive textile sensor* untuk memantau data terkait dengan persediaan, seperti ada atau tidaknya produk, situasi *stockout*, jumlah produk, waktu penempatan dan pengambilan produk, dan sebagainya (Hossain dkk., 2020).

c. Kebijakan pemesanan atau *replenishment*

Terdapat kebutuhan untuk mengelola dan mengendalikan persediaan dengan kebijakan yang sesuai untuk meningkatkan performa suatu organisasi dalam menghadapi ketidakpastian pada sektor retail. Kehilangan niat membeli merupakan salah satu kerugian terbesar pada suatu organisasi dan salah satunya disebabkan oleh situasi *stockout*. Tetapi, dalam upaya mengatasi masalah *stockout*, situasi kelebihan stok dapat terjadi dan akhirnya berdampak pada peningkatan biaya penyimpanan (Obot dkk., 2019). Salah satu metode dalam menentukan kebijakan pemesanan atau *replenishment* adalah menggunakan metode pemodelan matematis, seperti *economic order quantity* (EOQ). Briseño-Oliveros dkk. (2019) melakukan penelitian untuk menentukan kebijakan *replenishment* pada retail cat menggunakan model EOQ klasik dengan terlebih dahulu mengklasifikasikan persediaan menggunakan metode klasifikasi ABC untuk mengidentifikasi produk yang memiliki dampak signifikan. Kebijakan persediaan sangat penting untuk dianalisis dalam suatu bisnis, termasuk retail. Obot dkk. (2019) juga melakukan penelitian terhadap kebijakan *replenishment* pada produk di supermarket menggunakan model EOQ dan *fuzzy* EOQ dengan terlebih dahulu mengklasifikasikan produk berdasarkan pola permintaannya, yaitu musiman dan non musiman. Hasil penelitian menyatakan bahwa tingkat penghematan terhadap biaya persediaan ketika menggunakan model EOQ dan *fuzzy* EOQ bergantung pada kondisi lingkungan pada suatu organisasi, misalnya pemadaman listrik yang sering serta kenaikan tarif transportasi akibat harga bahan bakar yang mahal dan kondisi jalan yang buruk. Selain menggunakan pemodelan matematis, seperti EOQ, terdapat juga pendekatan lain untuk menentukan kebijakan persediaan terutama jika memiliki banyak parameter yang bersifat probabilistik, yaitu dengan simulasi sistem. Sridhar dkk. (2021) melakukan simulasi sistem untuk meminimasi tingkat persediaan dengan tetap menjaga tingkat pelayanan (*service level*). Simulasi dilakukan dengan perangkat lunak Arena dan menggunakan modul OptQuest untuk menentukan parameter kuantitas pemesanan dan titik pemesanan ulang (*reorder point*) yang optimal. Penggunaan metode simulasi untuk menentukan kebijakan persediaan, khususnya *reorder point* pada retail, juga dilakukan oleh Witthayapraphakorn & Jaijit (2023). Penelitian tersebut berusaha untuk menentukan *reorder point* yang paling optimal untuk memenuhi *service level* yang ditentukan (90%) dengan mempertimbangkan permintaan, *lead time*, dan kerusakan produk yang tidak pasti. Kebijakan

persediaan optimal yang dihasilkan dari simulasi sistem berpengaruh pada kenaikan/penurunan tingkat persediaan pada setiap jenis produk, meningkatkan total profit harian, dan mengurangi total produk yang rusak. Penentuan kebijakan persediaan lainnya adalah dengan mempertimbangkan tingkat permintaan yang merupakan fungsi dari ruang persediaan yang dialokasikan untuk produk di rak dengan memodelkan ketidakpastian tingkat permintaan secara linear, polynomial, dan eksponensial dengan mempertimbangkan fungsi objektif untuk memaksimalkan ekspektasi profit (Srivastava et al., 2023). Pengembangan kebijakan persediaan dengan permintaan yang tidak pasti juga dilakukan oleh Saffari (2022) yang mengasumsikan bahwa distribusi probabilitas permintaan bergantung pada tingkat dan panjang periode persediaan. Analisis kebijakan persediaan pada penelitian tersebut melibatkan fungsi profit yang terdiri dari pendapatan penjualan, biaya penyimpanan, biaya kekurangan, dan biaya pemesanan. Penelitian tersebut menemukan bahwa berdasarkan studi numerik, nilai optimal variabel keputusan tidak mengikuti pola konsisten (tidak bersifat *monotonic*) seiring dengan perubahan sensitivitas permintaan terhadap persediaan. Pengembangan kebijakan persediaan juga dapat diintegrasikan dengan pemilihan pemasok seperti pada penelitian yang dilakukan oleh Sutrisno dkk. (2023). Penelitian tersebut memiliki fungsi tujuan untuk meminimasi total biaya operasional dengan mempertimbangkan adanya diskon dan beberapa parameter ketidakpastian dan disintesis ke dalam *piecewise fuzzy-probabilistic optimization model*. Selain kebijakan persediaan optimal yang harus ditentukan untuk mengatasi masalah persediaan, terdapat faktor lain yang mempengaruhi persediaan pada suatu retail, seperti pembusukan, kadaluarsa, kerusakan akibat kesalahan penanganan oleh karyawan/pelanggan, atau pencurian. Bassamboo dkk. (2020) melakukan penelitian untuk mengatasi masalah pemeriksaan dan *replenishment* pada persediaan yang tidak tercatat (*phantom inventory*) menggunakan *polynomial-time algorithm*. Dalam pengembangan kebijakan persediaan, tidak hanya mempertimbangkan fungsi tujuan yang berkaitan dengan biaya tetapi juga dapat mempertimbangkan tujuan dalam dimensi keberlanjutan. Paul dkk. (2022) melihat adanya peningkatan praktik retail hijau pada saat ini sehingga melakukan penelitian untuk menentukan waktu *replenishment* dan tingkat kepedulian terhadap lingkungan yang optimal. Model persediaan dikembangkan dengan mempertimbangkan penurunan kualitas produk (*deterioration*), permintaan yang sensitif terhadap harga dan tingkat kepedulian

terhadap lingkungan, biaya persediaan dan pajak karbon. Penelitian lain yang melibatkan dimensi keberlanjutan pada masalah persediaan dilakukan oleh Gioia dkk. (2023) pada manajemen persediaan retail dengan produk yang mudah rusak (*perishable*). Penentuan kebijakan pemesanan dilakukan menggunakan optimasi berbasis simulasi dengan mempertimbangkan ketidakpastian yang berasal dari pasokan, permintaan, kualitas, dan faktor lain seperti musiman, perilaku konsumen, serta potensi produk pengganti karena *stockout*.

2.1.3. Implementasi *Artificial Intelligence* (AI) pada Manajemen Persediaan

Dewasa ini, antusiasme terhadap AI dalam sektor retail cukup tinggi, tetapi terdapat ketidakpastian terhadap dimana area terbaik untuk menerapkan AI dalam rantai nilai retail serta terkait dengan tingkat pengembalian investasi (*return on investment*) (Oosthuizen et al., 2021). Implementasi AI dapat diterapkan dalam proses peramalan permintaan/penjualan yang merupakan salah satu tahapan dalam manajemen persediaan. Benhamida dkk. (2021) mengembangkan metode peramalan permintaan dengan mengusulkan dua metode peramalan, yaitu 1) metode hibrida, Comb-TSB, yang digunakan untuk pola permintaan *intermittent* dan *lumpy*. Metode tersebut secara otomatis memilih model yang paling akurat dari sekumpulan model peramalan. 2) Pendekatan berbasis *clustering* (ClustAvg) yang diusulkan untuk permintaan produk baru yang hanya memiliki sedikit atau bahkan tidak ada data historis penjualan. Wang dkk. (2023) melakukan pengembangan metode optimalisasi manajemen persediaan pada *e-commerce business-to-consumer* (B2C) dengan menerapkan teknik *feature engineering* pada set data sebagai dasar untuk melakukan peramalan permintaan menggunakan model regresi linear, pohon keputusan (*decision tree*), *random forest*, dan *neural network*. Pemanfaatan AI sebagai metode peramalan juga dilakukan oleh Ashwini Rekha & Vijaykumar (2019). Penelitian tersebut memanfaatkan *machine learning* (ML) untuk melakukan peramalan terhadap segmen yang paling menguntungkan karena sebagian retail besar memiliki banyak cabang di lokasi berbeda. Selanjutnya, terdapat pengembangan model peramalan penjualan yang mengintegrasikan metode pembuatan keputusan (*Best-Worst Method*) dan *data mining* (*k-Means*) ke dalam model *Recency-Frequency-Monetary* yang disebut sebagai SalesKBR. Penggunaan AI dalam manajemen persediaan juga digunakan untuk mengklasifikasikan persediaan untuk tujuan tertentu. Qaffas dkk. (2023) melakukan klasifikasi persediaan dengan menggunakan *multi-criteria ABC classification*. *Multi-criteria ABC classification* bermanfaat untuk pengendalian dan

optimasi persediaan secara otomatis. Penelitian tersebut mengembangkan metode *multi-criteria ABC classification* yang dapat diinterpretasikan agar pembuat keputusan dapat memahami kelompok yang diberikan terhadap persediaan dengan menggunakan metode *eXplainable AI* dengan *Shapley Additive exPlanations* karena metode klasifikasi ABC yang sudah ada beroperasi sebagai proses *blackbox* AI yang hanya menyediakan pemberian klasifikasi tanpa menyediakan penjelasan manajerial. Penelitian selanjutnya adalah pemanfaatan AI untuk mengidentifikasi dan mengklasifikasi adanya *potential dead stock* dan *dead stock*. Klasifikasi dilakukan dengan meningkatkan metode klasifikasi persediaan dengan mengintegrasikan sisa umur rak produk sebagai indikator *dead stock*. Klasifikasi dilakukan dengan menggunakan algoritma *decision tree*. Dengan adanya klasifikasi tersebut, lebih dari satu ton emisi karbon dapat dicegah dengan lebih sedikit pembuangan limbah *dead stock* (Li dkk., 2023). Selain dalam peramalan dan klasifikasi, AI juga digunakan untuk mengembangkan algoritma yang mengatasi sistem distribusi dan persediaan pada *one-warehouse multi-retailer*. Algoritma yang dikembangkan pada penelitian tersebut menggunakan *deep reinforcement learning* yang dapat menutup kekurangan algoritma sebelumnya (heuristik) yang memerlukan waktu lama dan harus dilakukan ulang pada setiap varian masalah (Kaynov dkk., 2024). Teknologi AI juga diterapkan dalam sistem pemantauan persediaan. Sikkandhar dkk. (2023) melakukan pengembangan sistem manajemen *real-time* dengan deteksi kesalahan peletakan barang atau kehilangan stok pada retail. Sistem yang dikembangkan adalah *conductive polymer-based interactive shelving system* yang melibatkan sensor berbasis *polymer* yang dapat mendeteksi berat dan bentuk dari *stockkeeping unit* (SKU). Data tersebut kemudian dianalisis menggunakan model TensorFlow untuk identifikasi SKU. Sistem yang dikembangkan dapat mengatasi *stockout* pada retail yang disebabkan penanganan persediaan secara manual dan kesalahan peletakan barang yang menyumbang hingga 4% *lost sales*. Sistem *smart retail shelves* juga dikembangkan oleh Agarwal dkk. (2020) dengan menggunakan *computer vision* dan *deep learning*. Sistem yang dikembangkan menghasilkan penghematan biaya dan keuntungan bagi retail dalam memprediksi pemesanan persediaan. Sistem pemantauan persediaan dengan memanfaatkan AI juga dikembangkan oleh Milella dkk. (2020) menggunakan *depth camera* untuk menghasilkan peringatan dan memberikan pembaharuan ketersediaan produk secara kontinyu, estimasi pemesanan persediaan, dan *replenishment*.

Tabel 2.1. Kontribusi Penelitian pada Isu Energi pada Retail Berkelanjutan

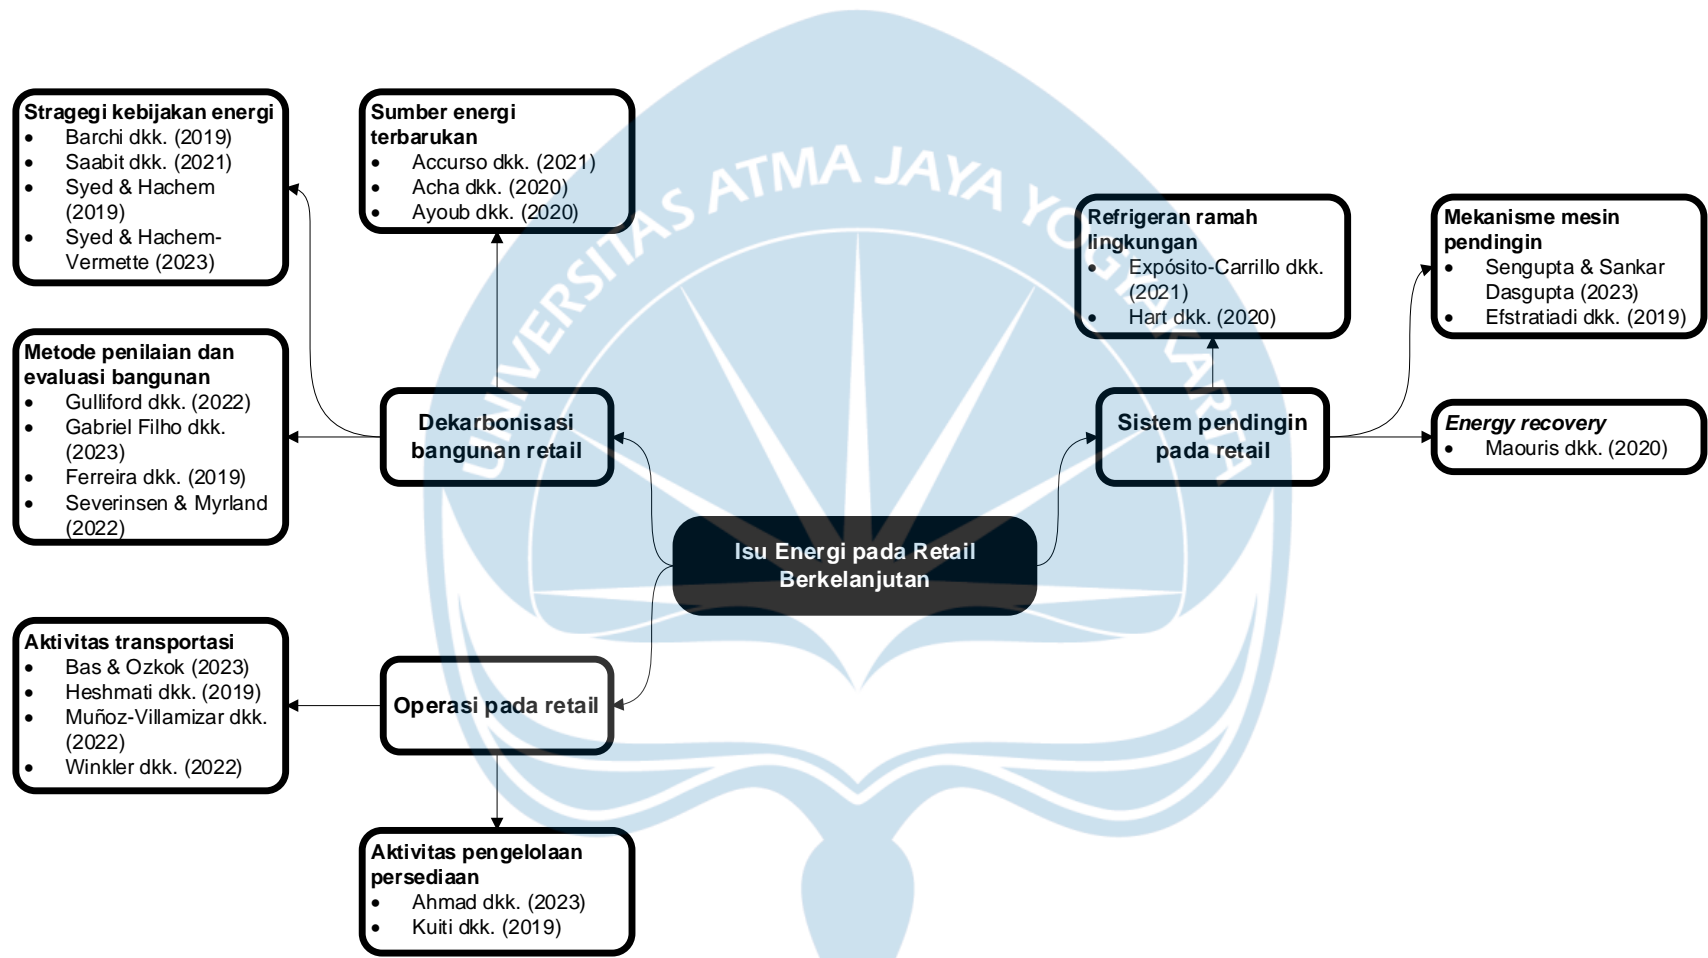
Penulis	Isu Energi pada Retail Berkelanjutan		
	Bangunan Retail	Operasi pada Retail	Sistem Pendingin
Barchi dkk. (2019)	✓		
Saabit dkk. (2021)	✓		
Syed & Hachem (2019)	✓		
Syed & Hachem-Vermette (2023)	✓		
Gulliford dkk. (2022)	✓		
Gabriel Filho dkk. (2023)	✓		
Ferreira dkk. (2019)	✓		
Severinsen & Myrland (2022)	✓		
Accurso dkk. (2021)	✓		
Acha dkk. (2020)	✓		
Ayoub dkk. (2020)	✓		
Bas & Ozkok (2023)		✓	
Heshmati dkk. (2019)		✓	
Muñoz-Villamizar dkk. (2022)		✓	
Winkler dkk. (2022)		✓	
Ahmad dkk. (2023)		✓	
Kuiti dkk. (2019)		✓	
Expósito-Carrillo dkk. (2021)			✓
Hart dkk. (2020)			✓
Sengupta & Sankar Dasgupta (2023)			✓
Efstratiadi dkk. (2019)			✓
Maouris dkk. (2020)			✓
Penelitian ini		✓	✓

Tabel 2.2. Kontribusi Penelitian pada Manajemen Persediaan di Sektor Retail

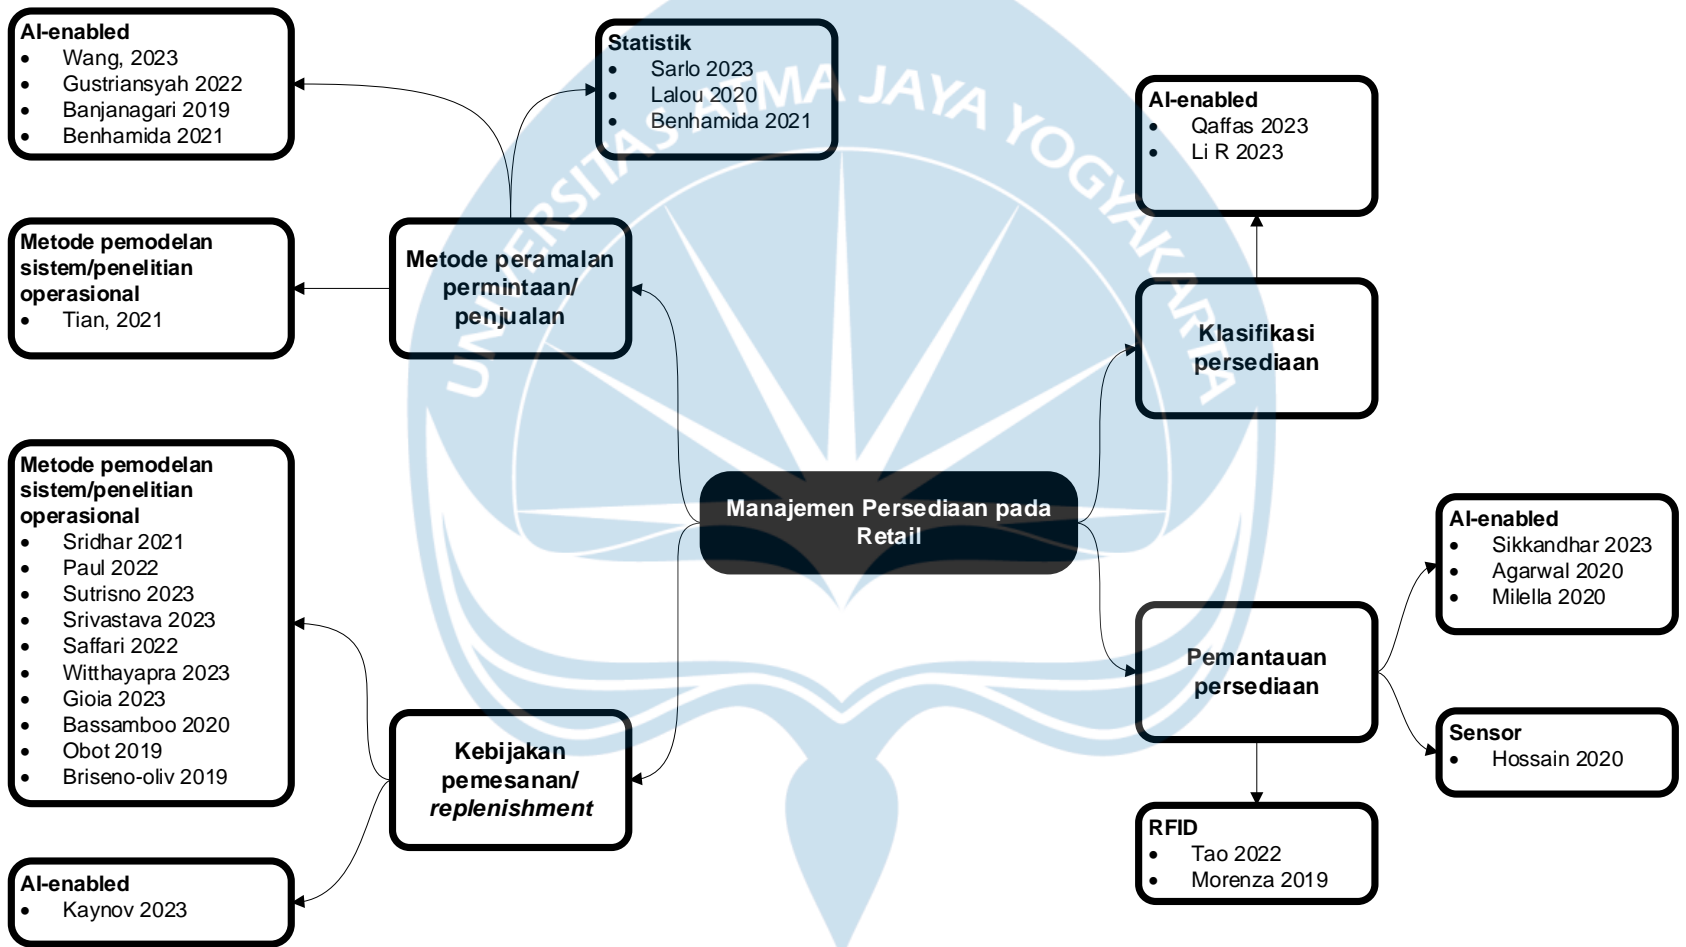
Penulis	Aspek Keberlanjutan	Manajemen Persediaan			Pendekatan		
		Peramalan	Klasifikasi Persediaan	Kebijakan Pemesanan/ Replenishment	Pemodelan Sistem/ Penelitian Operasional	Statistik	Berbasis AI
Wang dkk. (2023)							
Gustriansyah dkk. (2022)							
Ashwini Rekha & Vijaykumar (2019)		✓					✓
Benhamida dkk. (2021)							
Tian dkk. (2021)		✓					
Sarlo dkk. (2023)							
Lalou dkk. (2020)		✓				✓	
Benhamida dkk. (2021)							
Sridhar dkk. (2021)							
Sutrisno dkk. (2023)							
Srivastava dkk. (2023)							
Saffari (2022)							
Witthayapraphakorn & Jajit (2023)				✓			
Bassamboo dkk. (2020)							
Obot dkk. (2019)							
Briseño-Oliveros dkk. (2019)							
Paul dkk. (2022)	✓			✓			
Gioia dkk. (2023)							
Kaynov dkk. (2024)				✓			
Qaffas dkk. (2023)			✓				✓
Li dkk. (2023)	✓		✓				✓
Penelitian ini	✓			✓			✓

Tabel 2.3. Kontribusi Penelitian pada Sistem Pemantauan Persediaan

Penulis	<i>Stock Visibility</i>		
	Perangkat Sensor/IoT	Berbasis AI	RFID
Sikkandhar dkk. (2023)			
Agarwal dkk. (2020)		✓	
Milella dkk. (2020)			
Tao dkk. (2022)			
Morenza-Cinos dkk. (2019)			✓
Hossain dkk. (2020)	✓		
Penelitian ini	✓	✓	



Gambar 2.1. Mind Map Isu Energi pada Retail Berkelanjutan

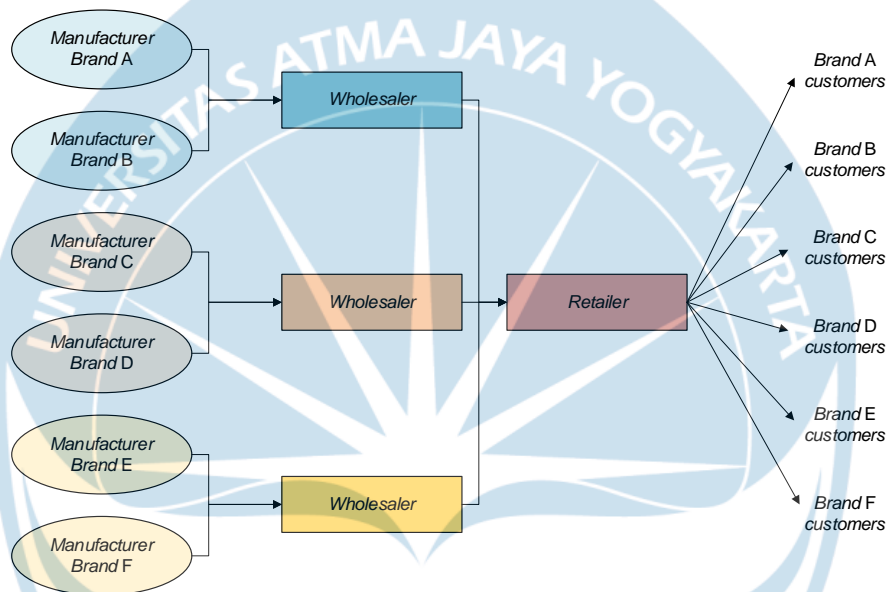


Gambar 2.2. Mind Map Manajemen Persediaan pada Retail

2.2. Dasar Teori

2.2.1. Operasi pada Retail

Menurut Berman dkk. (2017), retail merupakan aktivitas bisnis yang melibatkan penjualan barang dan jasa kepada pembeli untuk penggunaan pribadi, keluarga, atau rumah tangganya. Dalam proses distribusi, retail menduduki tahapan paling akhir dan berperan sebagai pihak yang menghubungkan antara manufaktur, pedagang grosir, dan konsumen akhir. Gambar 2.3 menunjukkan saluran distribusi yang terdiri dari manufaktur hingga konsumen akhir.



Gambar 2.3. Saluran Distribusi dan Peran Retail dalam Proses Sorting

Sumber: Berman dkk. (2017)

Berdasarkan Gambar 2.3, retail bertugas untuk mengumpulkan berbagai macam jenis barang dari berbagai sumber, membelinya dalam jumlah besar, dan menjualnya dalam jumlah kecil yang disebut sebagai proses *sorting*.

Dalam menjalankan retail, terdapat beberapa operasi yang harus dilakukan, mulai dari pengelolaan sumber daya manusia serta pengelolaan operasi yang dapat ditinjau dari sisi dimensi finansial dan operasional itu sendiri. Pengelolaan sumber daya manusia meliputi penentuan tugas yang harus dilakukan, menyiapkan struktur organisasi, merekrut dan mengelola personel, dan sebagainya. Pengelolaan operasi dari dimensi finansial meliputi perencanaan keuntungan, manajemen aset, penganggaran, dan alokasi sumber daya. Sementara pengelolaan retail dalam dimensi operasional, meliputi format toko, alokasi ukuran

dan ruangan, utilisasi staf, perawatan toko, manajemen energi, dan renovasi, manajemen persediaan, keamanan toko, asuransi, teknologi dan komputerisasi.

2.2.2. Manajemen Persediaan

Menurut Taha (2017), di dalam rantai pasok terdapat tiga jenis aliran, yaitu aliran barang, informasi, dan uang. Secara umum, aliran barang berkebalikan dengan aliran uang. Sementara aliran informasi dapat terjadi secara dua arah. Aliran informasi memerlukan kolaborasi yang erat antara semua pihak di dalam rantai pasok. Dari berbagai jenis informasi yang mengalir, data penjualan pada tingkat konsumen merupakan informasi yang paling penting karena data tersebut digunakan untuk memprediksi distribusi permintaan terhadap suatu barang. Informasi penjualan tersebut kemudian dapat digunakan untuk menentukan tingkat optimal maupun pergerakan barang dari dan ke seluruh pihak dalam rantai pasok.

a. Elemen dalam model optimasi persediaan

Persediaan yang terlalu banyak pada suatu organisasi akan meningkatkan biaya penyimpanan (*holding cost*) yang timbul akibat aktivitas untuk menjaga persediaan yang ada (modal, penyimpanan, serta penanganan persediaan). Sementara, persediaan yang terlalu sedikit dapat meningkatkan kemungkinan terjadinya kekosongan produk (*shortage*) sehingga meningkatkan biaya kekosongan (*shortage cost*). Persediaan yang dimiliki akan berkurang seiring digunakannya dalam aktivitas suatu organisasi. Hal tersebut menyebabkan persediaan akan diisi ulang secara periodik dengan membuat pesanan baru kepada pemasok. Setiap pesanan baru akan menimbulkan biaya persiapan (*setup cost*) yang tidak bergantung dari kuantitas produk yang dipesan. Biaya pembelian (*purchasing cost*) dari pemasok, dalam banyak kasus, dapat mendapatkan potongan harga ketika melakukan pemesanan dalam kuantitas besar. Dari pernyataan tersebut, biaya total persediaan (*total inventory cost*) dapat dirumuskan ke dalam Persamaan 2.1.

$$\left(\begin{array}{c} \text{Total} \\ \text{inventory} \\ \text{cost} \end{array} \right) = \left(\begin{array}{c} \text{Purchasing} \\ \text{cost} \end{array} \right) + \left(\begin{array}{c} \text{Setup} \\ \text{cost} \end{array} \right) + \left(\begin{array}{c} \text{Holding} \\ \text{cost} \end{array} \right) + \left(\begin{array}{c} \text{Shortage} \\ \text{cost} \end{array} \right) \quad (2.1)$$

Selain beberapa komponen biaya klasik yang telah dijelaskan, pada saat ini terdapat berbagai komponen biaya yang juga diperhitungkan dalam menganalisis biaya total pada persediaan. Contoh komponen biaya yang dapat diperhitungkan adalah biaya karbon dari aktivitas yang berhubungan dengan manajemen

persediaan, seperti penyimpanan dan transportasi (Astanti dkk., 2022; Tao dkk., 2018). Komponen biaya karbon juga dipertimbangkan karena saat ini terdapat perhatian yang tinggi terhadap dampak lingkungan dari kegiatan industri. Dengan mengintegrasikan biaya karbon dalam analisis biaya, perusahaan tidak hanya dapat mengoptimalkan efisiensi operasional tetapi juga berkontribusi pada upaya pengurangan jejak karbon dan peningkatan keberlanjutan. Pertimbangan ini sejalan dengan tren global untuk mengurangi dampak lingkungan dan memenuhi tuntutan konsumen yang semakin peduli terhadap isu lingkungan.

b. Pengaruh permintaan pada pengembangan model persediaan

Kompleksitas model persediaan bergantung pada permintaan, apakah bersifat deterministik atau probabilistik. Pola permintaan dalam model persediaan dapat diasumsikan ke dalam satu dari beberapa tipe yaitu deterministik dan konstan (statis) terhadap waktu, deterministik dan variabel (dinamis) terhadap waktu, probabilistik dan stasioner terhadap waktu, probabilistik dan non stasioner terhadap waktu.

2.2.3. Simulasi Berbasis Peristiwa

Simulasi berbasis peristiwa (*event-driven simulation model* atau *discrete-event simulation*) merupakan simulasi yang mengamati titik waktu tertentu dimana perubahan tertentu terjadi pada sistem (Rossetti, 2016). Teknik simulasi memiliki kelebihan untuk dapat memodelkan sistem yang kompleks yang biasanya terdiri dari peristiwa yang terjadi secara acak.

a. *Input modelling*

Input modeling digunakan untuk menentukan distribusi probabilitas pada suatu input random. *Input modeling* seringkali digunakan pada simulasi. Sebagai contoh pada simulasi sistem antrian, *input model* yang digunakan adalah distribusi waktu kedatangan dan waktu layanan. Pada simulasi rantai pasok, *input model* yang digunakan adalah distribusi permintaan dan *lead time* (Banks dkk., 2014; Law, 2014). Terdapat empat langkah yang digunakan untuk mengembangkan *input model*:

i. Pengumpulan data

Pengumpulan data memerlukan komitmen terhadap waktu dan sumber daya. Dalam keadaan tertentu, terdapat kondisi dimana data tidak dapat dikumpulkan, misalnya waktu yang sangat terbatas atau terdapat larangan untuk mengumpulkan data.

- ii. Identifikasi distribusi probabilitas untuk menggambarkan proses *input*
- Identifikasi jenis distribusi probabilitas diawali dengan pembentukan histogram yang berfungsi untuk melihat bentuk distribusi dari suatu data yang telah dikumpulkan. Hal yang cukup berpengaruh dalam pembentukan histogram adalah penentuan jumlah interval setial kelas. Jika interval terlalu lebar, histogram tidak menampilkan bentuk distribusi secara detil. Sedangkan jika interval terlalu sempit, bentuk histogram akan kasar. Berdasarkan bentuk histogram, terdapat beberapa jenis distribusi yang umum digunakan, antara lain Binomial, Binomial negatif, Poisson, Normal, Lognormal, Eksponensial, Gamma, Beta, Erlang, Weibull, Seragam, Triangular, dan Empiris.
- iii. Memilih parameter yang menggambarkan distribusi tertentu
- Pemilihan parameter distribusi diawali dengan menganalisis statistik deskriptif, seperti rata-rata dan varian. Langkah selanjutnya adalah menentukan estimator untuk mengestimasi parameter distribusi yang akan diuji. Tabel 2.4 merupakan estimator pada distribusi yang sering digunakan.

Tabel 2.4. Estimator Distribusi

Sumber: Banks dkk. (2014)

<i>Distribution</i>	<i>Parameter(s)</i>	<i>Suggested Estimator(s)</i>
Poisson	α	$\hat{\alpha} = \bar{X}$
Exponential	λ	$\hat{\lambda} = \frac{1}{\bar{X}}$
Gamma	β, θ	$\hat{\beta}$ $\hat{\theta} = \frac{1}{\bar{X}}$
Normal	μ, σ^2	$\hat{\mu} = \bar{X}$ $\hat{\sigma}^2 = S^2$ (unbiased)
Lognormal	μ, σ^2	$\hat{\mu} = \bar{X}$ (after taking <i>ln</i> of the data) $\hat{\sigma}^2 = S^2$ (after taking <i>ln</i> of the data)
Weibull with $v=0$	α, β	$\hat{\beta}_0 = \frac{\bar{X}}{S}$ $\hat{\beta}_j = \hat{\beta}_{j-1} \frac{f(\hat{\beta}_{j-1})}{f(\hat{\beta}_{j-1})}$ $\hat{\alpha} = \left(\frac{1}{n} \sum_{i=1}^n X_i^{\hat{\beta}} \right)^{1/\hat{\beta}}$
Beta	β_1, β_2	$\Psi(\hat{\beta}_1) + \Psi(\hat{\beta}_1 - \hat{\beta}_2) = \ln(G_1)$ $\Psi(\hat{\beta}_2) + \Psi(\hat{\beta}_1 - \hat{\beta}_2) = \ln(G_2)$ Where Ψ is the digamma function, $G_1 = (\prod_{i=1}^n X_i)^{1/n}$ and $G_2 = (\prod_{i=1}^n (1-X_i))^{1/n}$

- iv. Evaluasi pada jenis distribusi yang dipilih dan parameter untuk mengetahui tingkat kesesuaiannya (disebut juga uji *goodness-of-fit*)

Uji *goodness-of-fit* digunakan untuk menguji apakah data masukan sesuai atau mengikuti distribusi probabilitas yang telah ditentukan pada tahap sebelumnya. Terdapat dua jenis uji yang dapat digunakan, yaitu Kolmogorov-Smirnov dan chi-square.

b. *Output analysis*

Suatu simulasi dapat dilakukan dengan satu atau beberapa replikasi. Replikasi merupakan pembangkitan satu sample yang merepresentasikan evolusi sistem dari kondisi awal hingga kondisi akhir. Replikasi merupakan sample yang berbeda dengan kondisi awal yang sama dan menggunakan pengaturan parameter input yang sama. Hasil dari setiap replikasi memiliki kemungkinan yang berbeda meskipun diawal dengan kondisi yang sama dan parameter yang sama. Hal tersebut disebabkan karena adanya elemen acak yang ada di dalam sistem. Selain itu, hasil dari setiap replikasi tidak dipengaruhi oleh replikasi lainnya. Penggunaan replikasi pada simulasi bertujuan untuk memperoleh gambaran perilaku sistem yang diamati dengan lebih akurat dan memungkinkan evaluasi yang lebih andal dari hasil simulasi. Dengan menggunakan beberapa replikasi, kita dapat memperoleh berbagai jalur sampel yang menggambarkan bagaimana sistem dapat berperilaku di bawah kondisi yang sama namun dengan variasi acak yang berbeda.

Salah satu metode yang dapat digunakan untuk membantu menilai akurasi estimasi hasil simulasi adalah *half width*. *Half width* bertujuan untuk mengukur rentang interval kepercayaan (*confidence interval*) dari hasil simulasi. Penentuan *half width* dapat dilakukan dengan Persamaan 2.2.

$$h = t_{\frac{\alpha}{2}, n-1} \frac{s}{\sqrt{n}} \quad (2.2)$$

Semakin banyak jumlah replikasi, maka nilai *half width* akan semakin berkurang yang menandakan variabilitas hasil setiap replikasi juga berkurang. Semakin kecil nilai *halfwidth* menunjukkan semakin akurat gambar perilaku sistem yang diamati sehingga dapat digunakan untuk membantu dalam pengambilan keputusan.

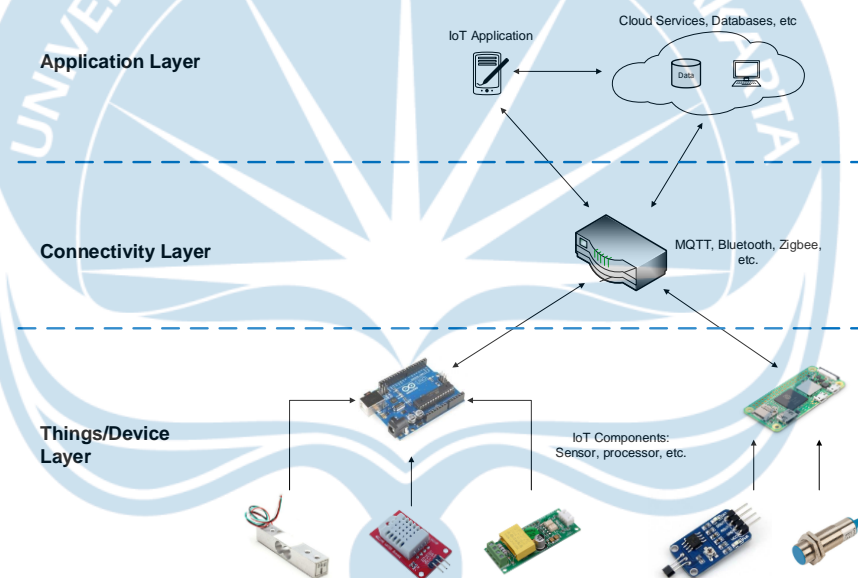
2.2.4. Internet of Things

a. Pengertian *Internet of Things*

Istilah *Internet of Things* (IoT) digunakan pertama kali oleh Kevin Ashton pada tahun 1999 dalam konteks manajemen rantai pasok dengan *radio frequency identification* (RFID) atau barang dengan *barcode* yang menawarkan efisiensi dan akuntabilitas yang lebih baik pada bisnis (Ashton, 2009). *Internet of Things* merupakan sebuah jaringan dari sekumpulan benda (*things*) – dilengkapi dengan sensor – yang terhubung dengan internet (Minerva dkk., 2015).

b. Arsitektur *Internet of Things*

Menurut Schoder (2018), terdapat tiga lapisan dalam IoT, yaitu *things/device layer*, *connectivity layer*, dan *application layer*. Gambar 2.4 merupakan ilustrasi lapisan dalam IoT.



Gambar 2.4. Arsitektur IoT

Sumber: Dokumentasi Pribadi

i. *Things/device layer*

Lapisan ini terdiri dari perangkat keras utama atau perangkat yang akan dihubungkan dengan jaringan. Selain itu, terdapat komponen IoT yang terdiri dari sensor, aktuator, prosesor, dan konektivitas jaringan. Komponen selanjutnya adalah perangkat lunak yang digunakan untuk menjalankan perangkat fisik IoT.

ii. *Connectivity layer*


Lapisan ini terdiri dari protokol yang memungkinkan adanya komunikasi antara perangkat IoT, infrastruktur jaringan, dan/atau layanan *cloud*.

iii. *Application layer*

Lapisan tertinggi pada arsitektur IoT yang berfungsi sebagai antarmuka sistem IoT dengan manusia, manajemen data dan analitis, dan aplikasi lain yang berfungsi untuk membuat atau mengatur perangkat IoT dan memanfaatkan data dari IoT.

2.2.5. *Artificial Intelligence*

Artificial Intelligence (AI) dibagi menjadi tiga tingkatan, yaitu 1) AI yang mulai dikembangkan pada tahun 1950an, dengan adanya kemampuan komputer untuk meniru kecerdasan manusia untuk memecahkan masalah, 2) *Machine Learning* (ML), bagian dari AI yang mengajarkan komputer untuk belajar dan membuat keputusan, dan 3) *Deep Learning* (DL), bagian dari ML yang mengekstrak fitur objek melalui sejumlah besar data lalu mengidentifikasi dan mengklasifikasikan informasi yang didapat (Liu dkk., 2022). Gambar 2.5 menunjukkan relasi AI, ML, dan DL secara lebih jelas.




Gambar 2.5. Relasi antara AI, ML, dan DL

Sumber: Pradhan & Kumar (2019)

a. *Model Neural Network*

Neural Network (NN) memodelkan *neuron* pada otak manusia. NN terdiri dari *node*, *weight*, dan *activation* yang dapat dilihat pada Gambar 2.6. *Node* mengendalikan fungsi jaringan dan melakukan komputasi. *Weight* menghubungkan ke satu atau lebih *node* untuk pengiriman sinyal. *Activation* menentukan pengiriman sinyal dari satu *node* ke *node* lain.



Gambar 2.6. Neural Network

Sumber: Liu dkk. (2022)

b. Klasifikasi *Neural Network*

Berdasarkan mekanisme pembelajaran, NN dibagi menjadi tiga kategori, yaitu *supervised learning*, *semi-supervised learning*, dan *unsupervised learning*.

i. *Supervised learning*

Supervised learning menentukan *target* dan *train* dengan *input* dari set data untuk meminimasi kesalahan antara hasil yang diharapkan dengan hasil yang diprediksi. Model *supervised learning* yang terkenal adalah *Convolutional Neural Network* (CNN) dan *Recurrent Neural Network* (RNN).

ii. *Semi-supervised learning*

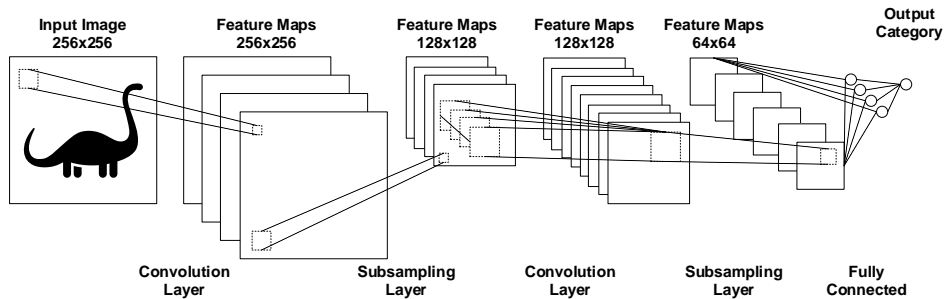
Semi-supervised learning merujuk pada label *output* yang tidak menyeluruh pada *training*. Salah satu contoh algoritmanya adalah *Reinforcement learning* (RL).

iii. *Unsupervised learning*

Unsupervised learning merupakan jaringan yang mempelajari fitur penting dari set data yang memanfaatkan relasi antar *input* melalui *clustering*, *dimensionality reduction*, dan *generative technique*. Contoh algoritma yang termasuk *unsupervised learning* adalah *auto encoder* (AE), *restricted Boltzmann machine* (RBM), dan *deep belief network* (DBM).

c. *Convolutional Neural Network* (CNN)

Convolutional Neural Network (CNN) merupakan suatu *neural network* yang digunakan untuk pemrosesan gambar dan permasalahan klasifikasi (Singh, 2019). CNN merupakan *neural network* yang memproses gambar dengan serangkaian lapisan konvolusi dan *pooling* yang berlapis dan *output* pada lapisan terakhir diteruskan pada lapisan *fully connected* kemudian ke lapisan *softmax* (Venkatesan & Li, 2017). Gambar 2.7 merupakan contoh lapisan pada CNN.



Gambar 2.7. Lapisan pada CNN

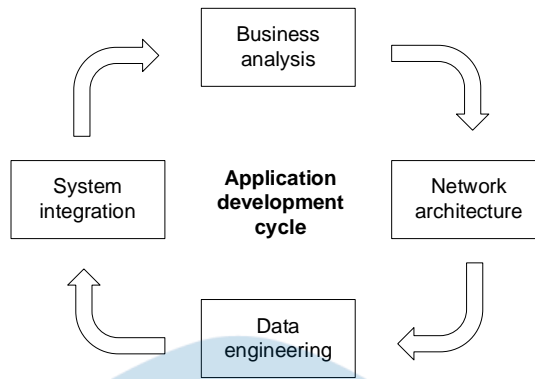
Sumber: Singh (2019)

Berikut ini merupakan penjelasan dari lapisan yang terdapat pada CNN:

- i. Lapisan konvolusi
Lapisan konvolusi merupakan lapisan pertama pada CNN. Lapisan ini mengaplikasikan filter (*kernel*) pada gambar *input*. Filter akan bergeser ke seluruh gambar untuk menghasilkan peta fitur (*feature map*) untuk mendeteksi pola tertentu pada gambar. Langkah ini akan menghasilkan gambar dengan resolusi yang lebih rendah.
- ii. Lapisan subsampling
Lapisan subsampling atau lapisan *pooling* atau lapisan *downsampling* berfungsi untuk mengurangi dimensi peta fitur yang dihasilkan lapisan konvolusi sebelumnya. Pengurangan dimensi bertujuan untuk mengurangi kompleksitas komputasi, menjaga fitur yang paling signifikan, dan mengurangi risiko *overfitting*. Teknik yang dapat digunakan seperti *max pooling* atau *average pooling*.
- iii. Lapisan *fully connected*
Lapisan ini menerima *output* yang telah diratakan menjadi satu dimensi dari lapisan sebelumnya. Lapisan *fully connected* bertugas untuk klasifikasi akhir dengan menghubungkan setiap neuron dengan neuron di lapisan sebelumnya. Lapisan ini memperhitungkan seluruh fitur yang telah diekstrak dari lapisan sebelumnya untuk membuat prediksi. Pada lapisan *fully connected* terakhir, biasanya digunakan fungsi aktivasi *softmax* untuk klasifikasi multi-kelas atau *sigmoid* untuk klasifikasi biner.

d. Pengembangan aplikasi berbasis AI

Terdapat empat tahapan besar dalam siklus pengembangan aplikasi AI yang dapat dilihat pada Gambar 2.8.



Gambar 2.8. Siklus Pengembangan Aplikasi AI

Sumber: Liu dkk. (2022)

i. *Business planning*

Langkah awal adalah pengembangan tujuan AI, pemahaman masalah, keuntungan, dan *trade-off* teknologi. Perencanaan tidak hanya berfokus pada isu teknis tetapi juga mempertimbangkan budaya perusahaan, staf, dan manajemen lalu memutuskan bagaimana mengintegrasikan AI ke dalam lingkungan bisnis yang ada.

ii. *Network design*

Pemahaman masalah dan kebutuhan untuk menentukan arsitektur NN yang sesuai. Tahap ini juga menentukan kriteria *input* dan *output* yang diinginkan, serta menyempurkan rancangan untuk mencapai performa yang optimal.

iii. *Data engineering*

Tahap *data engineering* mengumpulkan data struktural dan non struktural dan menerjemahkannya menjadi bentuk yang sesuai untuk pembelajaran model. Validasi *output* dilakukan dengan spesifikasi rancangan untuk hasil prediksi yang akurat.

iv. *System integration*

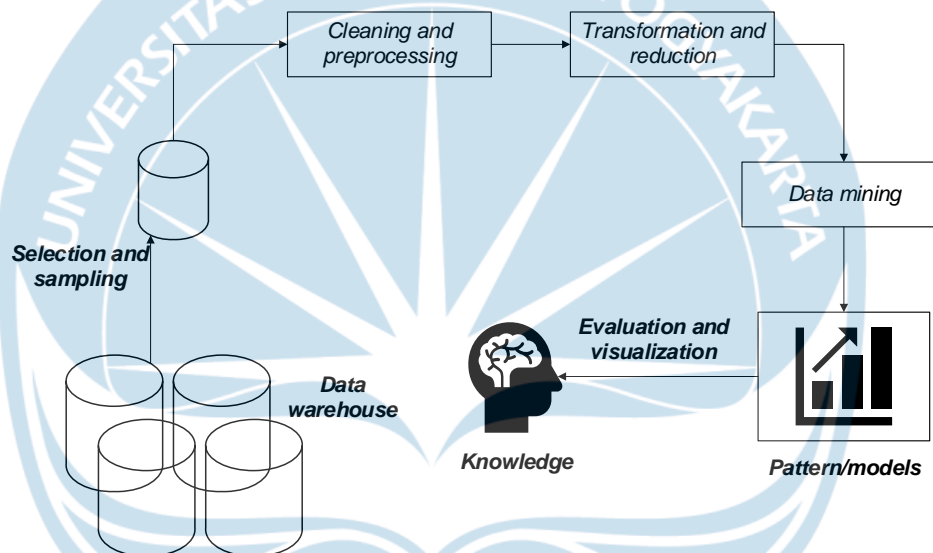
Tahap integrasi aplikasi ke dalam lingkungan bisnis melalui antar muka yang mudah digunakan.

2.2.6. Knowledge Discovery in Database

Berdasarkan Fayyad (2001), *data mining* dan *Knowledge Discovery in Database* (KDD) merupakan area penelitian yang berkembang dengan cepat yang melibatkan beberapa disiplin ilmu, yaitu statistic, basis data, pengenalan pola/AI, visualisasi, dan komputasi performa tinggi dan paralel. Istilah *data mining* sering

digunakan sebagai padanan kata dari proses mendapatkan informasi yang berguna dari basis data. Tetapi terdapat perbedaan makna dari KDD dan *data mining*. KDD merupakan proses keseluruhan untuk menemukan pengetahuan yang berguna dari data, sementara *data mining* merujuk pada salah satu langkah dalam KDD.

Langkah dalam KDD meliputi persiapan data, pemilihan data, pembersihan data, menggabungkan pengetahuan sebelumnya yang sesuai, dan interpretasi yang sesuai terhadap hasil yang ditunjukkan pada Gambar 2.9. Pada proses KDD, suatu tahap dapat diulangi hingga berkali-kali dan urutan prosesnya tidak selalu mulus karena terdiri dari banyak percobaan.



Gambar 2.9. Proses KDD

Sumber: Fayyad (2001)