

BAB II

TINJAUAN PUSTAKA

2.1 Kajian Teoritis

2.1.1 *Inventory management*

Konsep *inventory management* atau manajemen persediaan merupakan fondasi utama dalam menjaga kelancaran operasional suatu organisasi. Menurut Muller (2003) dalam *Essentials of Inventory Management* menjelaskan bahwa persediaan mencakup seluruh sumber daya berupa bahan baku, barang dalam proses, hingga produk jadi yang dikelola baik secara fisik maupun dalam sistem pencatatan perusahaan. Sejalan dengan itu, Simbolon (2021) mendefinisikan persediaan sebagai aset yang digunakan untuk menunjang proses produksi maupun memenuhi permintaan konsumen secara berkelanjutan. Dengan demikian, manajemen persediaan dapat disintesis sebagai suatu sistem pengelolaan sumber daya yang bertujuan menjaga keseimbangan antara ketersediaan barang dan efisiensi biaya operasional.

Secara operasional, persediaan memiliki fungsi sebagai *buffer* untuk menghadapi ketidakpastian permintaan, fluktuasi pasokan, serta ketidaksesuaian waktu antara kebutuhan dan ketersediaan barang. Muller (2003) menjelaskan bahwa keberadaan persediaan memungkinkan perusahaan tetap menjalankan operasional secara stabil meskipun terjadi variasi dalam sistem. Selain itu, faktor-faktor seperti *lead time*, tingkat permintaan, serta biaya pemesanan dan penyimpanan turut mempengaruhi kinerja sistem persediaan (Simbolon, 2021). Bahagia (2006) menambahkan bahwa efektivitas sistem persediaan ditentukan oleh kemampuan dalam menyeimbangkan tingkat pelayanan (*service level*) dengan total biaya persediaan.

Dalam perspektif *Operations Research*, efektivitas sistem manajemen persediaan tidak hanya dilihat dari ketersediaan barang, tetapi juga dari kemampuan sistem dalam meminimalkan total biaya persediaan. Total biaya persediaan (*total cost*) pada dasarnya merupakan fungsi *trade-off* antara beberapa komponen utama, yaitu biaya pemesanan (*ordering cost*), biaya penyimpanan (*holding cost*), dan biaya kekurangan persediaan (*stockout cost*), yang dapat dirumuskan sebagai:

$$TC = OC + HC + SC$$

Hubungan antar komponen biaya tersebut bersifat *trade-off*, di mana peningkatan jumlah persediaan dapat menurunkan risiko kekurangan stok, namun meningkatkan biaya penyimpanan. Sebaliknya, pengurangan persediaan dapat menekan biaya penyimpanan, tetapi meningkatkan risiko *stockout*.

Pada persediaan dengan karakteristik *perishable*, model biaya perlu diperluas dengan memasukkan komponen tambahan berupa biaya kedaluwarsa (*expiration cost*). Biaya ini timbul akibat barang yang tidak digunakan sebelum masa simpannya berakhir sehingga tidak lagi memiliki nilai guna. Dengan demikian, fungsi total biaya persediaan dapat diperluas menjadi:

$$TC = OC + HC + SC + EC$$

Keberadaan komponen biaya ini menambah kompleksitas dalam pengambilan keputusan persediaan, karena sistem tidak hanya harus menyeimbangkan antara *holding cost* dan *stockout cost*, tetapi juga meminimalkan risiko pemborosan akibat kedaluwarsa.

Meskipun demikian, dalam konteks operasional penelitian ini, optimasi *Expiration Cost* (EC) tidak dimodelkan melalui fungsi matematis deteriorasi secara terpisah. Penurunan biaya kedaluwarsa

dicapai secara tidak langsung dan *preventif* melalui penentuan kuantitas pemesanan (Q) yang presisi berbasis prediksi XGBoost, guna meminimalkan peluang terjadinya penumpukan stok.

Lebih lanjut, pengendalian persediaan (*inventory control*) merupakan bagian integral dari sistem operasi dan rantai pasok. Vollmann dkk. (2011) menjelaskan bahwa pengendalian persediaan merupakan bagian dari sistem *manufacturing planning and control* yang berperan dalam mengoordinasikan perencanaan kebutuhan material, pengendalian produksi, serta distribusi. Sementara itu, Fogarty dkk. (1991) menyatakan bahwa pengendalian persediaan bertujuan untuk menentukan jumlah dan waktu pemesanan yang optimal guna meminimalkan total biaya persediaan dengan tetap mempertahankan tingkat pelayanan yang diinginkan.

Dalam implementasinya, pengendalian persediaan melibatkan berbagai kebijakan seperti penentuan *safety stock* dan *reorder point* (ROP) untuk mengantisipasi ketidakpastian permintaan dan *lead time*. Vollmann dkk. (2011) menekankan bahwa ketidakpastian tersebut menjadi faktor utama yang mempengaruhi kinerja sistem persediaan, sehingga diperlukan pendekatan yang adaptif dalam pengambilan keputusan.

Seiring dengan perkembangan teknologi dan ketersediaan data, pendekatan tradisional dalam pengendalian persediaan mulai berkembang menuju pendekatan berbasis data (*data-driven*), di mana hasil peramalan permintaan digunakan sebagai dasar dalam pengambilan keputusan. Dalam konteks penelitian ini, pendekatan tersebut diimplementasikan melalui penggunaan algoritma *machine learning*, khususnya XGBoost, untuk menghasilkan prediksi permintaan yang lebih akurat. Hasil prediksi tersebut kemudian digunakan dalam perhitungan *safety stock* dan *reorder point* secara

dinamis, sehingga sistem persediaan menjadi lebih adaptif terhadap perubahan pola permintaan, khususnya pada reagen laboratorium *Quality Control* yang bersifat fluktuatif dan memiliki keterbatasan masa simpan.

2.1.2 Pengendalian persediaan

Pengendalian persediaan (*inventory control*) merupakan implementasi operasional dari manajemen persediaan yang berfokus pada pengaturan jumlah, waktu, dan mekanisme pemesanan barang secara spesifik. Jika manajemen persediaan menitikberatkan pada aspek strategis, maka pengendalian persediaan berperan dalam memastikan keputusan operasional terkait stok dapat dilakukan secara tepat dan terukur.

Menurut Simbolon (2021) pengendalian persediaan bertujuan untuk menjamin ketersediaan barang dalam jumlah yang sesuai pada waktu yang dibutuhkan dengan biaya yang minimum. Sementara itu, Bahagia (2006) menyatakan bahwa sistem pengendalian persediaan dirancang untuk menghadapi ketidakpastian baik dari sisi permintaan maupun pasokan melalui pendekatan yang sistematis. Dengan demikian, pengendalian persediaan tidak hanya berfungsi menjaga ketersediaan, tetapi juga sebagai mekanisme pengambilan keputusan dalam kondisi yang tidak pasti.

Secara teknis, pengendalian persediaan melibatkan beberapa parameter utama, yaitu tingkat permintaan, waktu tunggu pemenuhan (*lead time*), serta tingkat pelayanan (*service level*). Parameter tersebut menjadi dasar dalam penentuan kebijakan stok, termasuk penentuan kapan pemesanan kembali harus dilakukan dan berapa jumlah persediaan yang perlu disediakan. Dalam praktiknya, kebijakan ini diimplementasikan melalui konsep persediaan pengaman (*safety stock*)

dan titik pemesanan kembali (*reorder point*), yang berfungsi untuk mengantisipasi fluktuasi permintaan maupun keterlambatan pasokan.

Selain itu, pengendalian persediaan juga mempertimbangkan *trade-off* antara risiko kekurangan stok (*stockout*) dan kelebihan stok (*overstock*). Persediaan yang terlalu rendah berpotensi mengganggu kelancaran operasional, sedangkan persediaan yang terlalu tinggi dapat meningkatkan biaya penyimpanan serta risiko penurunan kualitas, terutama pada material yang memiliki keterbatasan masa simpan. Oleh karena itu, sistem pengendalian persediaan harus mampu menyeimbangkan tingkat ketersediaan dengan efisiensi biaya secara optimal.

Dalam konteks penelitian ini, pengendalian persediaan memiliki peran penting karena karakteristik permintaan reagen pada laboratorium *Quality Control* bersifat fluktuatif dan tidak stabil dari hari ke hari. Kondisi tersebut menyebabkan pendekatan pengendalian persediaan konvensional yang berbasis rata-rata historis menjadi kurang responsif terhadap perubahan kebutuhan aktual. Oleh karena itu, diperlukan pendekatan yang lebih adaptif melalui integrasi hasil peramalan berbasis data, sehingga kebijakan pengendalian seperti *safety stock* dan *reorder point* dapat ditentukan secara lebih akurat dan dinamis.

2.1.3 Sistem Pengendalian Persediaan *Continuous Review*

Sistem pengendalian persediaan *continuous review* merupakan salah satu metode pengendalian persediaan probabilistik yang melakukan pemantauan tingkat persediaan secara terus-menerus (*continuous monitoring*). Dalam sistem ini, setiap perubahan jumlah persediaan akibat pemakaian maupun penerimaan barang akan langsung dicatat sehingga kondisi stok dapat diketahui setiap saat.

Heizer dkk. (2017) menjelaskan bahwa *continuous review system* atau sistem-Q merupakan sistem pengendalian persediaan di mana tingkat persediaan dipantau secara kontinu dan pemesanan kembali dilakukan ketika persediaan mencapai titik pemesanan kembali (*reorder point*). Dengan demikian, sistem ini memungkinkan perusahaan melakukan pengendalian stok secara lebih responsif terhadap perubahan permintaan.

Secara operasional, *continuous review system* bekerja dengan menggunakan dua parameter utama, yaitu jumlah pemesanan tetap (*fixed order quantity*) dan titik pemesanan kembali (*reorder point/ROP*). Ketika tingkat persediaan turun hingga mencapai nilai ROP, sistem akan secara otomatis memicu pemesanan kembali dengan jumlah tertentu yang relatif tetap. Oleh karena itu, sistem ini sering disebut sebagai sistem (Q,R), di mana Q menunjukkan kuantitas pemesanan dan R menunjukkan *reorder point*. Hillier & Lieberman (2015) menjelaskan bahwa pendekatan probabilistik pada sistem *continuous review* digunakan untuk mengantisipasi ketidakpastian permintaan maupun lead time melalui penggunaan *safety stock* sebagai buffer persediaan.

Dalam pendekatan *continuous review*, *reorder point* ditentukan berdasarkan kebutuhan selama lead time ditambah dengan persediaan pengaman (*safety stock*) untuk mengantisipasi ketidakpastian permintaan maupun keterlambatan pasokan. Dengan demikian, sistem ini mampu menjaga tingkat pelayanan (*service level*) agar tetap optimal sekaligus meminimalkan risiko kekurangan persediaan (*stockout*). Selain itu, *continuous review* memungkinkan perusahaan merespons perubahan permintaan secara lebih cepat dibandingkan sistem *periodic review* yang hanya melakukan evaluasi stok pada interval waktu tertentu. Rahayu & Manurung (2024) menyatakan bahwa sistem

continuous review lebih responsif terhadap fluktuasi permintaan karena pengawasan persediaan dilakukan secara real-time.

Secara teoritis, *continuous review system* lebih sesuai digunakan pada item dengan tingkat permintaan tinggi, nilai kritis tinggi, atau risiko *stockout* yang besar. Sistem ini memungkinkan keputusan pemesanan dilakukan secara lebih cepat karena tingkat persediaan selalu dipantau secara kontinu. Namun demikian, penerapan *continuous review* membutuhkan sistem pencatatan dan monitoring yang lebih kompleks dibandingkan *periodic review* karena setiap transaksi persediaan harus dicatat secara langsung. Heizer dkk. (2017) menjelaskan bahwa perkembangan teknologi informasi dan sistem komputerisasi membuat penerapan *continuous review* menjadi lebih mudah dilakukan dalam sistem operasional modern.

Selain itu, sistem *continuous review* memiliki keterkaitan yang erat dengan metode *Economic Order Quantity* (EOQ). Dalam sistem (Q,R), nilai Q umumnya ditentukan menggunakan pendekatan EOQ sebagai jumlah pemesanan ekonomis, sedangkan nilai R ditentukan berdasarkan *reorder point*. Dengan demikian, *continuous review* tidak hanya menentukan kapan pemesanan dilakukan, tetapi juga menentukan jumlah pemesanan optimal untuk meminimalkan total biaya persediaan.

Dalam konteks persediaan *perishable*, *continuous review* memiliki peran penting karena karakteristik produk yang sensitif terhadap waktu dan fluktuasi permintaan. Persediaan dengan umur simpan terbatas memerlukan pengawasan stok secara lebih ketat agar risiko kekurangan stok maupun kelebihan stok yang berpotensi mengalami kedaluwarsa dapat diminimalkan. Nahmias & Olsen (2015) menjelaskan bahwa sistem *continuous review* pada *perishable inventory* memungkinkan pengambilan keputusan pemesanan

dilakukan secara lebih adaptif berdasarkan kondisi persediaan aktual serta pola permintaan yang berubah secara dinamis.

Dalam penelitian ini, *continuous review system* digunakan sebagai dasar pendekatan pengendalian persediaan karena mampu mengakomodasi perubahan permintaan reagen laboratorium yang bersifat fluktuatif dan termasuk kategori *fast-moving*. Melalui pendekatan ini, hasil prediksi permintaan yang diperoleh dari algoritma XGBoost dapat digunakan secara dinamis dalam menentukan *reorder point* dan *safety stock*. Dengan demikian, sistem persediaan menjadi lebih responsif terhadap perubahan kebutuhan aktual serta mampu meminimalkan risiko *stockout*, *overstock*, dan pemborosan akibat kedaluwarsa.

2.1.4 **Economic Order Quantity (EOQ)**

Economic Order Quantity (EOQ) merupakan salah satu metode klasik dalam pengendalian persediaan yang digunakan untuk menentukan jumlah pemesanan optimal sehingga total biaya persediaan dapat diminimalkan. Silver dkk. (2017) menjelaskan bahwa EOQ merupakan model pengendalian persediaan yang bertujuan menentukan kuantitas pemesanan ekonomis melalui keseimbangan antara biaya pemesanan (*ordering cost*) dan biaya penyimpanan (*holding cost*). Metode ini banyak digunakan dalam sistem pengendalian persediaan karena memiliki konsep yang sederhana dan mampu membantu perusahaan dalam menentukan kebijakan pemesanan secara lebih efisien.

Model EOQ pertama kali diperkenalkan oleh Ford W. Harris pada tahun 1913 dan hingga saat ini masih menjadi dasar dalam berbagai model pengendalian persediaan modern. Dalam penerapannya, EOQ digunakan untuk menentukan jumlah pemesanan

yang paling ekonomis sehingga perusahaan dapat menjaga keseimbangan antara frekuensi pemesanan dan biaya penyimpanan persediaan. Jika jumlah pemesanan terlalu kecil, maka frekuensi pemesanan akan meningkat sehingga biaya pemesanan menjadi lebih besar. Sebaliknya, apabila jumlah pemesanan terlalu besar, maka biaya penyimpanan akan meningkat akibat akumulasi stok yang terlalu tinggi.

Secara umum, model EOQ mempertimbangkan dua komponen biaya utama, yaitu biaya pemesanan (*ordering cost*) dan biaya penyimpanan (*holding cost*). Biaya pemesanan merupakan biaya yang timbul setiap kali perusahaan melakukan pemesanan bahan atau produk, seperti biaya administrasi, biaya pengiriman, dan biaya penerimaan barang. Sementara itu, biaya penyimpanan merupakan biaya yang muncul akibat penyimpanan persediaan dalam gudang, seperti biaya sewa gudang, biaya pemeliharaan, biaya asuransi, serta risiko kerusakan dan kedaluwarsa produk. Muckstadt & Sapra (2010) menjelaskan bahwa nilai EOQ diperoleh pada kondisi ketika total biaya pemesanan dan total biaya penyimpanan berada pada titik minimum sehingga total biaya persediaan menjadi optimal.

Secara matematis, rumus *Economic Order Quantity* dapat dinyatakan sebagai berikut:

$$EOQ = \sqrt{\frac{2DS}{H}}$$

Keterangan:

D = jumlah permintaan tahunan (*annual demand*)

S = biaya pemesanan setiap kali pesan (*ordering cost*)

H = biaya penyimpanan per unit per tahun (*holding cost*)

Rumus tersebut digunakan untuk menentukan jumlah pemesanan optimal yang mampu menghasilkan total biaya persediaan

minimum. Dalam praktiknya, nilai EOQ juga digunakan untuk menentukan frekuensi pemesanan dan interval waktu pemesanan dalam suatu periode tertentu.

Model EOQ klasik dibangun berdasarkan beberapa asumsi dasar. Silver dkk. (1998) menjelaskan bahwa asumsi utama dalam model EOQ meliputi tingkat permintaan yang bersifat konstan dan diketahui, lead time tetap, tidak terjadi *stockout*, penerimaan barang dilakukan sekaligus dalam satu waktu, serta harga produk per unit dianggap tetap. Selain itu, model EOQ klasik juga mengasumsikan bahwa produk yang disimpan tidak mengalami kerusakan maupun penurunan kualitas selama periode penyimpanan.

Meskipun EOQ memiliki konsep yang sederhana dan mudah diterapkan, model ini memiliki keterbatasan dalam kondisi operasional nyata yang bersifat dinamis. Pada sistem persediaan dengan permintaan yang fluktuatif, pendekatan EOQ klasik menjadi kurang fleksibel karena tidak mempertimbangkan perubahan pola permintaan secara kontinu. Selain itu, pada produk yang bersifat *perishable*, penyimpanan dalam jumlah besar dapat meningkatkan risiko kedaluwarsa dan pemborosan. Medina-Santana & Cárdenas-Barrón (2020) menyatakan bahwa pengembangan model EOQ modern mulai mempertimbangkan faktor ketidakpastian permintaan, karakteristik produk, serta aspek keberlanjutan untuk meningkatkan efektivitas sistem persediaan.

Dalam penelitian ini, metode EOQ diintegrasikan ke dalam kerangka *continuous review system* untuk menentukan jumlah pemesanan ekonomis (Q) pada reagen laboratorium. Mengingat karakteristik reagen yang bersifat *fluktuatif* dan *perishable*, pendekatan EOQ ini tidak berdiri sendiri, melainkan dikombinasikan dengan parameter *reorder point* (ROP) dan *safety stock* yang bersifat dinamis hasil prediksi algoritma XGBoost.

2.1.5 *Fast moving items*

Klasifikasi *Fast-Moving, Slow-Moving, dan Non-Moving (FSN)* merupakan salah satu pendekatan dalam pengelolaan persediaan yang didasarkan pada tingkat pergerakan atau laju penggunaan suatu item dalam periode tertentu. Berdasarkan penelitian oleh Agustin & Hidayat (2025), klasifikasi FSN dilakukan dengan mengelompokkan item berdasarkan tingkat perputaran persediaan (*turnover ratio*), sehingga perusahaan dapat mengidentifikasi item dengan tingkat penggunaan tinggi, sedang, maupun rendah.

Konsep ini sejalan dengan pendekatan yang dikemukakan oleh Janari dkk. (2016), yang menyatakan bahwa klasifikasi FSN didasarkan pada frekuensi penggunaan material dalam satu periode waktu. Item yang termasuk kategori *fast-moving* merupakan item dengan tingkat pemakaian tinggi, sedangkan *slow-moving* memiliki frekuensi penggunaan yang lebih rendah, dan *non-moving* merupakan item yang tidak mengalami pergerakan dalam periode tertentu. Dengan demikian, klasifikasi FSN dapat dipahami sebagai metode untuk memetakan prioritas pengelolaan persediaan berdasarkan intensitas konsumsi aktual.

Secara teknis, pengelompokan FSN umumnya dilakukan menggunakan indikator *turnover ratio (TOR)*, yaitu rasio antara jumlah penggunaan atau pengeluaran barang terhadap rata-rata persediaan dalam periode tertentu. Nilai TOR yang tinggi menunjukkan bahwa suatu item memiliki perputaran yang cepat (*fast-moving*), sedangkan nilai yang rendah menunjukkan perputaran yang lambat atau bahkan tidak bergerak. Dalam implementasinya, klasifikasi ini memungkinkan perusahaan untuk menentukan kebijakan persediaan yang berbeda

untuk setiap kategori, seperti penentuan jumlah stok, frekuensi pemesanan, serta prioritas penyimpanan.

Lebih lanjut, hasil klasifikasi FSN memiliki implikasi langsung terhadap pengendalian persediaan. Item *fast-moving* memerlukan perhatian lebih dalam hal ketersediaan stok untuk menghindari risiko *stockout*, sedangkan item *slow-moving* dan *non-moving* perlu dikendalikan agar tidak menimbulkan penumpukan persediaan atau *dead stock*. Penelitian menunjukkan bahwa sebagian besar item dengan tingkat perputaran tinggi membutuhkan pengelolaan yang lebih responsif dan adaptif, terutama dalam penentuan *safety stock* dan frekuensi pemesanan.

Dalam konteks penelitian ini, konsep *fast-moving items* menjadi sangat relevan karena reagen laboratorium yang diteliti termasuk dalam kategori dengan tingkat penggunaan tinggi dan fluktuatif. Kondisi ini menuntut sistem pengendalian persediaan yang mampu merespon perubahan permintaan secara cepat dan akurat. Oleh karena itu, identifikasi item *fast-moving* menjadi dasar penting dalam menentukan fokus analisis, khususnya dalam penerapan metode peramalan berbasis *machine learning* serta perhitungan *reorder point* dan *safety stock* yang lebih adaptif.

2.1.6 Karakteristik *perishable* dan *fast-moving inventory*

Persediaan *perishable* merupakan jenis persediaan yang memiliki umur simpan terbatas dan mengalami penurunan kualitas atau nilai seiring waktu hingga akhirnya tidak dapat digunakan. Dalam konteks penelitian ini, reagen laboratorium *Quality Control* tidak hanya memiliki karakteristik *perishable*, tetapi juga termasuk dalam kategori *fast-moving items*, yaitu material dengan tingkat perputaran tinggi dan frekuensi penggunaan yang intensif. Dengan demikian, objek penelitian

memiliki dua karakteristik sekaligus yang saling berinteraksi dalam sistem persediaan.

Karakteristik utama dari *perishable inventory* adalah adanya proses deteriorasi, yaitu penurunan nilai produk akibat faktor waktu yang menyebabkan barang kehilangan nilai guna maupun nilai ekonomisnya (Nahmias, 1982). Oleh karena itu, berbeda dengan persediaan *non-perishable*, waktu penyimpanan menjadi variabel kritis yang harus dipertimbangkan dalam sistem pengendalian persediaan.

Kombinasi antara karakteristik *fast-moving* dan *perishable* menciptakan kompleksitas yang lebih tinggi dalam pengendalian persediaan. Di satu sisi, sifat *fast-moving* menuntut ketersediaan stok yang tinggi untuk menghindari risiko *stockout*. Namun, di sisi lain, sifat *perishable* menuntut pengendalian jumlah persediaan secara ketat untuk menghindari kelebihan stok (*overstock*) yang berpotensi mengalami kedaluwarsa. Kondisi tersebut menunjukkan adanya trade-off yang lebih kompleks dalam sistem persediaan, yaitu antara menjaga ketersediaan stok untuk memenuhi permintaan yang tinggi dan membatasi jumlah persediaan untuk meminimalkan risiko pemborosan akibat kedaluwarsa. Trade-off ini menjadi tantangan utama dalam pengendalian persediaan pada material dengan karakteristik *fast-moving* dan *perishable* secara bersamaan.

Dalam pendekatan konvensional, model pengendalian persediaan seperti *Economic Order Quantity* (EOQ) umumnya mengasumsikan bahwa permintaan bersifat stabil serta barang dapat disimpan tanpa mengalami penurunan kualitas selama periode penyimpanan. Namun, asumsi tersebut tidak relevan dalam konteks *perishable inventory* yang bersifat *fast-moving*, karena permintaan cenderung fluktuatif dan terdapat batasan umur simpan yang mempengaruhi nilai produk. Kondisi ini menyebabkan model EOQ

klasik yang berdiri sendiri seringkali kurang fleksibel dalam mengakomodasi dinamika permintaan *perishable inventory*. Oleh karena itu, kelemahan ini dapat diatasi dengan mengintegrasikan rumusan matematis EOQ ke dalam sistem pengendalian dinamis, di mana parameter input permintaannya disuplai dari hasil peramalan adaptif menggunakan algoritma *Machine Learning*.

Selain keterbatasan umur simpan, karakteristik lain yang membedakan *perishable inventory* adalah dinamika permintaan yang dipengaruhi oleh kualitas produk. Permintaan terhadap produk cenderung menurun seiring dengan berkurangnya sisa umur simpan, sehingga produk yang mendekati masa kedaluwarsa memiliki tingkat permintaan yang lebih rendah dibandingkan produk yang masih segar (Aritonang dkk., 2024). Kondisi ini menunjukkan bahwa pengendalian persediaan tidak hanya berfokus pada jumlah stok, tetapi juga mempertimbangkan waktu dan kualitas produk secara simultan.

Implikasi dari karakteristik tersebut adalah munculnya trade-off dalam pengelolaan persediaan, yaitu antara risiko kelebihan persediaan (*overstock*) dan risiko kekurangan persediaan (*stockout*). Persediaan yang terlalu besar tidak hanya meningkatkan biaya penyimpanan (*holding cost*), tetapi juga meningkatkan risiko kerugian akibat kedaluwarsa produk (*expiration cost*), yang pada akhirnya menimbulkan pemborosan (*waste*). Sebaliknya, persediaan yang terlalu kecil berpotensi menyebabkan terganggunya operasional akibat ketidaktersediaan barang. Damgaard dkk. (2013) menyatakan bahwa kompleksitas *perishable inventory* terletak pada kebutuhan untuk menyeimbangkan ketidakpastian permintaan dengan keterbatasan umur simpan dalam satu kerangka pengambilan keputusan.

Untuk mendukung pengendalian tersebut, diperlukan mekanisme operasional yang mampu mengurangi risiko kedaluwarsa,

salah satunya melalui kebijakan pengeluaran barang yang mempertimbangkan umur simpan produk, seperti *First In First Out* (FIFO) atau *First Expired First Out* (FEFO). Kebijakan ini bertujuan untuk memastikan bahwa produk dengan umur simpan lebih pendek digunakan terlebih dahulu sehingga dapat meminimalkan pemborosan dalam sistem persediaan. Dengan demikian, aspek operasional dan kebijakan pengelolaan stok menjadi bagian yang tidak terpisahkan dari pengendalian *perishable inventory*.

Untuk mengatasi tantangan pada *perishable inventory*, penggunaan algoritma XGBoost memungkinkan peramalan permintaan dengan akurasi tinggi berbasis data historis. Tingkat presisi peramalan ini menjadi kunci krusial; kesalahan estimasi tidak hanya berdampak pada pembengkakan biaya simpan, tetapi juga memicu risiko kerugian massal akibat kedaluwarsa. Melalui prediksi XGBoost, jumlah pemesanan dapat ditentukan secara proporsional sesuai kebutuhan aktual operasional, sehingga akumulasi stok berlebih dapat dicegah dan pemborosan (*waste*) dapat ditekan secara optimal.

2.1.7 ***Demand forecasting***

Demand forecasting merupakan proses memperkirakan jumlah permintaan di masa mendatang berdasarkan data historis serta pola permintaan yang terbentuk dari waktu ke waktu. Peramalan permintaan menjadi komponen penting dalam pengendalian persediaan karena digunakan sebagai dasar dalam pengambilan keputusan terkait jumlah pemesanan, waktu pemesanan, serta penentuan kebijakan persediaan yang optimal.

Dalam konteks manajemen persediaan, peramalan termasuk dalam metode kuantitatif yang memanfaatkan data historis untuk memprediksi kebutuhan di masa depan. Bazargan (2021) menjelaskan

bahwa metode peramalan seperti *moving average*, *weighted moving average*, dan *exponential smoothing* merupakan teknik dasar dalam forecasting yang digunakan untuk menganalisis pola permintaan berdasarkan data masa lalu. Metode-metode ini umumnya digunakan dalam sistem persediaan tradisional karena relatif sederhana dan mudah diimplementasikan.

Namun demikian, perkembangan industri modern yang ditandai dengan tingginya volatilitas permintaan menyebabkan metode konvensional memiliki keterbatasan. Berdasarkan penelitian Micheal (2023), metode statistik tradisional sering kali tidak mampu menangkap pola permintaan yang kompleks, non-linear, serta dipengaruhi oleh berbagai faktor eksternal seperti promosi, musim, dan tren pasar. Hal ini menyebabkan akurasi peramalan menjadi kurang optimal, terutama pada produk dengan karakteristik *fast-moving* dan fluktuatif.

Selain itu, Al Mesfer (2023) menegaskan bahwa akurasi *demand forecasting* memiliki pengaruh langsung terhadap kinerja sistem persediaan. Ketidaktepatan dalam peramalan dapat menyebabkan ketidakseimbangan persediaan, baik dalam bentuk kelebihan stok (*overstock*) yang meningkatkan biaya penyimpanan, maupun kekurangan stok (*stockout*) yang berpotensi menurunkan tingkat pelayanan dan menyebabkan kehilangan penjualan. Oleh karena itu, peningkatan akurasi *forecasting* menjadi salah satu faktor kunci dalam optimalisasi pengendalian persediaan.

Seiring dengan perkembangan teknologi, metode *machine learning* mulai banyak digunakan sebagai alternatif dalam *demand forecasting*. Pendekatan ini mampu memanfaatkan data historis dalam jumlah besar serta mengintegrasikan berbagai variabel eksternal untuk menghasilkan prediksi yang lebih akurat. Micheal (2023) menyatakan bahwa algoritma seperti *Random Forest*, *Neural Network*, dan *XGBoost*

mampu menangkap hubungan non-linear serta pola kompleks dalam data permintaan, sehingga memberikan hasil peramalan yang lebih adaptif dibandingkan metode konvensional.

Dalam konteks penelitian ini, *demand forecasting* menjadi elemen kunci karena objek penelitian berupa material dengan karakteristik permintaan yang fluktuatif dan dominan *fast-moving*. Kondisi tersebut menuntut metode peramalan yang mampu menangkap pola dinamis secara lebih akurat. Oleh karena itu, penelitian ini mengadopsi pendekatan *machine learning*, khususnya algoritma XGBoost, untuk meningkatkan akurasi prediksi permintaan sebagai dasar dalam penentuan kebijakan persediaan seperti *safety stock* dan *reorder point*.

2.1.8 *Machine Learning*

Machine Learning merupakan cabang dari kecerdasan buatan yang berfokus pada pengembangan metode komputasional yang memungkinkan sistem untuk mempelajari pola dari data dan menghasilkan prediksi tanpa harus diprogram secara eksplisit. Murphy (2012) menjelaskan bahwa *machine learning* menyediakan pendekatan otomatis dalam mendeteksi pola pada data serta memanfaatkan pola tersebut untuk memprediksi data di masa mendatang. Sejalan dengan itu, Smola & Vishwanathan (2008) menyatakan bahwa *machine learning* merupakan proses pembelajaran berbasis data yang bertujuan untuk membangun model prediktif melalui pendekatan statistik dan optimisasi. Dengan demikian, *machine learning* dapat disintesis sebagai metode berbasis data yang mengintegrasikan statistik, matematika, dan komputasi untuk menghasilkan model prediksi yang adaptif.

Secara teknis, *machine learning* bekerja dengan memanfaatkan data historis sebagai input (*training data*) untuk membangun model yang mampu mengenali pola dan hubungan antar variabel. Kroese dkk. (2024), menjelaskan bahwa proses ini melibatkan tahapan utama seperti pengolahan data, pemodelan, serta evaluasi kinerja model menggunakan data uji (*test data*). Dalam implementasinya, *machine learning* dibagi menjadi beberapa kategori utama, yaitu *supervised learning* dan *unsupervised learning*. Murphy (2012) menyebutkan bahwa *supervised learning* digunakan untuk memprediksi output berdasarkan data berlabel, seperti regresi dan klasifikasi, sedangkan *unsupervised learning* digunakan untuk menemukan pola tersembunyi dalam data tanpa label.

Lebih lanjut, model *machine learning* dibangun berdasarkan prinsip optimisasi dan minimisasi kesalahan prediksi. Smola & Vishwanathan (2008) menjelaskan bahwa proses pembelajaran model bertujuan untuk meminimalkan fungsi kerugian (*loss function*) yang merepresentasikan selisih antara nilai prediksi dan nilai aktual. Selain itu, konsep *bias-variance trade-off* menjadi aspek penting dalam *machine learning*, di mana model harus mampu menyeimbangkan antara kompleksitas dan kemampuan generalisasi agar tidak terjadi *overfitting* maupun *underfitting*.

Dari sisi implementasi, Nyamawe dkk. (2025) menjelaskan bahwa *machine learning* melibatkan serangkaian tahapan mulai dari pengumpulan data, pembersihan data (*data preprocessing*), transformasi data, hingga pembangunan dan deployment model. Sementara itu, Theobald (2017) menekankan bahwa *machine learning* tidak dapat dilepaskan dari dasar statistik dan pemrograman, karena algoritma yang digunakan merupakan turunan dari metode statistik yang diimplementasikan melalui sistem komputasi. Hal ini

menunjukkan bahwa keberhasilan model *machine learning* sangat bergantung pada kualitas data serta pemilihan algoritma yang sesuai dengan karakteristik data.

Dalam konteks penelitian ini, *machine learning* digunakan sebagai pendekatan untuk mengatasi keterbatasan metode peramalan konvensional dalam menangani pola permintaan yang fluktuatif dan tidak linear. Karakteristik permintaan reagen laboratorium yang berubah-ubah dari hari ke hari menyebabkan pendekatan statistik sederhana menjadi kurang akurat. Oleh karena itu, *machine learning* dipilih karena kemampuannya dalam menangkap pola kompleks dan hubungan non-linear dalam data, sehingga dapat menghasilkan prediksi permintaan yang lebih presisi sebagai dasar dalam penentuan kebijakan persediaan seperti *safety stock* dan *reorder point*.

2.1.9 ***Extreme Gradient Boosting (XGBoost)***

Extreme Gradient Boosting (XGBoost) merupakan salah satu algoritma *machine learning* berbasis *ensemble learning* yang dikembangkan dari metode *gradient boosting*. Secara umum, *boosting* adalah teknik yang menggabungkan beberapa model lemah (*weak learners*) menjadi model yang lebih kuat untuk meningkatkan akurasi prediksi. Murphy (2012) menjelaskan bahwa pendekatan ensemble seperti *boosting* mampu meningkatkan performa model dengan cara menggabungkan hasil prediksi dari beberapa model secara iteratif. Sejalan dengan itu, Smola dan Vishwanathan (2008) menyatakan bahwa metode *boosting* bekerja dengan meminimalkan kesalahan prediksi melalui proses optimisasi bertahap terhadap fungsi kerugian (*loss function*).

XGBoost sendiri merupakan pengembangan dari *gradient tree boosting* yang dirancang untuk meningkatkan efisiensi komputasi dan

akurasi model secara signifikan. Chen & Guestrin (2016) menjelaskan bahwa XGBoost adalah sistem *tree boosting* yang bersifat scalable dan mampu menghasilkan performa prediksi yang tinggi pada berbagai permasalahan *machine learning*. Algoritma ini menggunakan pendekatan *ensemble* berbasis pohon keputusan (*decision tree*) di mana hasil prediksi diperoleh dari penjumlahan beberapa pohon regresi yang dibangun secara bertahap.

Secara teknis, XGBoost bekerja dengan membangun model secara iteratif melalui proses penambahan pohon keputusan baru untuk memperbaiki kesalahan dari model sebelumnya. Proses ini dilakukan dengan meminimalkan fungsi objektif yang terdiri dari dua komponen utama, yaitu fungsi kerugian (*loss function*) dan fungsi regularisasi. Chen & Guestrin (2016) menyatakan bahwa fungsi objektif dalam XGBoost dirumuskan sebagai kombinasi antara kesalahan prediksi dan penalti kompleksitas model untuk menghindari *overfitting*. Pendekatan ini membuat XGBoost tidak hanya fokus pada akurasi, tetapi juga menjaga kesederhanaan model.

Lebih lanjut, XGBoost memanfaatkan pendekatan *gradient boosting* berbasis turunan pertama dan kedua (*first-order* dan *second-order gradient*) untuk mengoptimalkan proses pembelajaran. Hal ini memungkinkan model untuk menangkap pola data yang kompleks dan non-linear secara lebih akurat dibandingkan metode konvensional. Selain itu, XGBoost dilengkapi dengan berbagai keunggulan teknis seperti *regularization*, *shrinkage*, dan *column subsampling* yang berfungsi untuk meningkatkan generalisasi model serta mencegah *overfitting*.

Keunggulan lain dari XGBoost terletak pada kemampuannya dalam menangani data berskala besar dan data yang memiliki nilai hilang (*missing values*). Algoritma ini menggunakan pendekatan

sparsity-aware yang memungkinkan pemrosesan data menjadi lebih efisien, serta mampu menentukan arah optimal dalam pembentukan pohon ketika terdapat data yang tidak lengkap . Selain itu, XGBoost juga dirancang dengan sistem komputasi yang efisien melalui teknik paralelisasi dan optimasi memori sehingga dapat digunakan pada *dataset* yang besar dengan waktu komputasi yang relatif cepat.

Dalam konteks penelitian ini, penggunaan XGBoost menjadi relevan karena karakteristik permintaan reagen laboratorium yang bersifat fluktuatif dan tidak linear. Metode peramalan konvensional cenderung memiliki keterbatasan dalam menangkap pola tersebut, sehingga diperlukan pendekatan yang lebih adaptif. XGBoost mampu mengakomodasi variasi permintaan harian dengan memanfaatkan pola historis secara lebih kompleks, sehingga menghasilkan prediksi yang lebih akurat. Hasil prediksi ini selanjutnya digunakan sebagai dasar dalam perhitungan *safety stock* dan *reorder point* secara dinamis, sehingga mendukung pengendalian persediaan yang lebih optimal pada laboratorium *Quality Control*.

2.1.10 Evaluasi model (RMSE & MAPE)

Evaluasi kinerja model peramalan merupakan tahap penting untuk mengukur tingkat akurasi hasil prediksi terhadap data aktual. Dalam proses peramalan, kesalahan (*error*) didefinisikan sebagai selisih antara nilai aktual dengan nilai hasil prediksi. Menurut Hyndman (2014), pengukuran kesalahan ini digunakan sebagai dasar dalam menentukan kualitas model peramalan serta membandingkan performa antar model yang digunakan.

Secara teknis, salah satu metrik yang umum digunakan adalah *Root Mean Square Error* (RMSE). RMSE dihitung sebagai akar dari rata-rata kuadrat selisih antara nilai aktual dan nilai prediksi, sehingga

memberikan penalti yang lebih besar terhadap kesalahan dengan nilai tinggi. Karakteristik ini membuat RMSE sensitif terhadap *outliers* dan sangat efektif digunakan untuk mengidentifikasi model yang menghasilkan kesalahan besar. Oleh karena itu, RMSE sering digunakan ketika akurasi absolut menjadi prioritas utama dalam evaluasi model.

Selain itu, *Mean Absolute Percentage Error* (MAPE) merupakan metrik evaluasi yang mengukur kesalahan dalam bentuk persentase terhadap nilai aktual. MAPE memberikan interpretasi yang lebih mudah dipahami karena menunjukkan seberapa besar deviasi prediksi dalam satuan persentase. Hal ini menjadikan MAPE banyak digunakan dalam konteks manajemen operasional dan pengendalian persediaan, karena dapat menggambarkan tingkat kesalahan relatif yang terjadi pada sistem peramalan.

Pemilihan metrik evaluasi harus disesuaikan dengan karakteristik data dan tujuan analisis. RMSE lebih menekankan pada akurasi absolut dan sensitif terhadap kesalahan besar, sedangkan MAPE lebih menekankan pada kemudahan interpretasi dalam bentuk persentase. Hyndman (2014) menegaskan bahwa penggunaan lebih dari satu metrik evaluasi diperlukan untuk memperoleh gambaran performa model secara lebih komprehensif.

Dalam konteks penelitian ini, RMSE dan MAPE digunakan untuk mengevaluasi performa model prediksi permintaan reagen yang dihasilkan oleh algoritma XGBoost. Penggunaan kedua metrik ini bertujuan untuk memastikan bahwa model memiliki tingkat kesalahan yang rendah baik secara absolut maupun relatif. Hal ini penting karena hasil prediksi akan digunakan sebagai dasar dalam perhitungan *safety stock* dan *reorder point*, sehingga tingkat akurasi model secara

langsung mempengaruhi efektivitas pengendalian persediaan pada laboratorium *Quality Control*.

Untuk mengevaluasi kinerja dan tingkat akurasi dari model peramalan yang dihasilkan, penelitian ini menggunakan metrik *Mean Absolute Percentage Error* (MAPE). Interpretasi dari nilai MAPE yang diperoleh akan dievaluasi berdasarkan skala klasifikasi yang dikemukakan oleh Lewis (1982), di mana nilai MAPE di bawah 10% dikategorikan sebagai peramalan yang sangat akurat, 10% hingga 20% dikategorikan baik, 20% hingga 50% dikategorikan sebagai peramalan yang layak (*reasonable*), dan nilai di atas 50% dikategorikan tidak akurat.

2.1.11 Safety stock dan reorder point (ROP)

Safety stock dan *reorder point* (ROP) merupakan komponen penting dalam sistem pengendalian persediaan yang digunakan untuk menjaga keseimbangan antara ketersediaan stok dan efisiensi operasional. Kedua konsep ini berperan dalam menentukan kapan dan berapa jumlah persediaan yang harus tersedia untuk mengantisipasi ketidakpastian dalam sistem.

Safety stock merupakan persediaan tambahan yang disediakan untuk mengantisipasi ketidakpastian permintaan maupun keterlambatan waktu pemenuhan (*lead time*). Menurut Bazargan (2021), *safety stock* berfungsi sebagai buffer untuk mengurangi risiko kekurangan stok (*stockout*) yang dapat mengganggu kelancaran operasional. Dengan adanya *safety stock*, sistem persediaan menjadi lebih fleksibel dalam menghadapi variasi permintaan dan ketidakpastian pasokan.

Secara teknis, besarnya *safety stock* dipengaruhi oleh beberapa faktor, antara lain variabilitas permintaan, variabilitas *lead time*, serta

tingkat pelayanan (*service level*) yang diinginkan. Dalam pendekatan probabilistik, *safety stock* dapat dirumuskan sebagai:

$$Safety\ Stock = Z \times \sigma_d \times \sqrt{L}$$

di mana:

Z = faktor tingkat pelayanan (*service level*)

σ_d = standar deviasi permintaan

L = *lead time*

Semakin tinggi tingkat ketidakpastian dan target pelayanan, maka semakin besar nilai *safety stock* yang diperlukan. Oleh karena itu, penentuan *safety stock* harus mempertimbangkan keseimbangan antara risiko *stockout* dan biaya penyimpanan (*holding cost*).

Sementara itu, *reorder point* (ROP) merupakan titik pemesanan kembali yang menunjukkan kapan suatu item harus dipesan ulang agar persediaan tidak habis selama periode *lead time*. Bazargan (2021) menjelaskan bahwa ROP ditentukan berdasarkan kebutuhan selama *lead time* serta persediaan pengaman yang tersedia. Secara umum, ROP dirumuskan sebagai:

$$ROP = d \times L + Safety\ Stock$$

di mana:

d = rata-rata permintaan

L = *lead time*

Rumus tersebut menunjukkan bahwa keputusan pemesanan tidak hanya bergantung pada kebutuhan rata-rata, tetapi juga mempertimbangkan ketidakpastian yang diakomodasi melalui *safety stock*.

Namun, pendekatan konvensional tersebut umumnya menggunakan nilai rata-rata historis yang bersifat statis, sehingga kurang mampu menangkap fluktuasi permintaan yang dinamis. Hal ini

menjadi keterbatasan terutama pada sistem persediaan dengan tingkat variabilitas tinggi, seperti pada *perishable inventory*.

Seiring berkembangnya pendekatan berbasis data, konsep *dynamic safety stock* dan *dynamic reorder point* mulai diterapkan. Dalam pendekatan ini, nilai permintaan tidak lagi menggunakan rata-rata historis, melainkan menggunakan hasil prediksi yang diperbarui secara berkala. Dalam penelitian ini, nilai permintaan diperoleh dari hasil prediksi menggunakan algoritma XGBoost yang mampu menangkap pola fluktuasi permintaan harian secara lebih akurat.

Variabilitas permintaan dalam pendekatan dinamis dapat diestimasi menggunakan error dari model peramalan. Salah satu metrik yang digunakan adalah *Root Mean Square Error* (RMSE), yang dirumuskan sebagai:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2}$$

di mana:

y_t = nilai aktual

$\hat{y}_t$ = nilai prediksi

n = jumlah data

Selain RMSE, evaluasi akurasi model juga dilakukan menggunakan *Mean Absolute Percentage Error* (MAPE) yang dirumuskan sebagai:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100\%$$

di mana:

y_t = nilai aktual

$\hat{y}_t$ = nilai prediksi

n = jumlah data

MAPE digunakan untuk mengukur rata-rata kesalahan prediksi dalam bentuk persentase terhadap nilai aktual, sehingga memudahkan interpretasi hasil evaluasi model dalam konteks operasional.

Dalam pendekatan probabilistik, *safety stock* umumnya dihitung berdasarkan standar deviasi permintaan sebagai representasi variabilitas kebutuhan. Namun, dalam sistem berbasis peramalan, variabilitas tersebut dapat didekati melalui error prediksi model. Menurut Hyndman (2014), RMSE mencerminkan dispersi kesalahan prediksi terhadap nilai aktual, sehingga dapat digunakan sebagai pendekatan untuk merepresentasikan ketidakpastian permintaan.

Selain itu, dalam penelitian ini, *lead time* diasumsikan bersifat konstan, sehingga variabilitas sistem hanya berasal dari permintaan. Dengan asumsi tersebut, sumber ketidakpastian dalam perhitungan *safety stock* hanya berasal dari permintaan atau error prediksi.

Penggunaan RMSE sebagai pengganti standar deviasi permintaan dilakukan dengan asumsi bahwa error prediksi berdistribusi normal dan tidak mengandung bias sistematis. Dalam kondisi tersebut, error prediksi dapat dianggap sebagai representasi dari variasi permintaan yang tidak dapat dijelaskan oleh model.

Dengan demikian, *safety stock* berbasis prediksi dapat dirumuskan sebagai:

$$Safety\ Stock = Z \times RMSE \times \sqrt{L}$$

Selanjutnya, *reorder point* juga menjadi dinamis karena bergantung pada hasil prediksi permintaan, sehingga dapat dirumuskan sebagai:

$$ROP = (\hat{d} \times L) + Safety\ Stock$$

di mana $\hat{d}$ merupakan hasil prediksi permintaan dari model XGBoost.

Dengan pendekatan ini, sistem pengendalian persediaan menjadi lebih responsif terhadap perubahan pola permintaan. Hal ini sangat penting terutama dalam konteks *perishable inventory*, di mana kesalahan dalam penentuan jumlah persediaan tidak hanya meningkatkan risiko *stockout*, tetapi juga meningkatkan potensi pemborosan akibat kedaluwarsa (*waste*). Oleh karena itu, integrasi antara metode peramalan berbasis *machine learning* dan perhitungan *safety stock* serta *reorder point* secara dinamis menjadi solusi yang efektif dalam meningkatkan efisiensi dan ketepatan pengendalian persediaan.

2.2 Penelitian terdahulu

Penelitian terdahulu digunakan sebagai dasar dalam memahami perkembangan metode yang digunakan dalam peramalan permintaan dan pengendalian persediaan. Selain itu, penelitian terdahulu juga membantu dalam mengidentifikasi kesenjangan penelitian yang menjadi dasar dilakukannya penelitian ini. Berikut merupakan ringkasan beberapa penelitian terdahulu yang relevan dengan topik penelitian.

Tabel 2.1 Penelitian Terdahulu

No	Nama	Judul	Hasil
1	Barghi & De (2025, École de Technologie Supérieure)	<i>Demand Forecasting and Inventory Improvement in Supply Chain Management Using Hybrid Boosting Ensemble Techniques</i>	Model hybrid boosting yang menggabungkan LightGBM, CatBoost, dan XGBoost mampu meningkatkan akurasi peramalan secara signifikan serta menurunkan tingkat <i>stockout</i> dan <i>overstock</i> , sehingga berkontribusi pada efisiensi biaya persediaan.

No	Nama	Judul	Hasil
2	Wagaw & Demisse (2025, Research Square)	<i>Prediction of Drug Procurement in Healthcare Supply Chains Using Machine Learning Algorithms</i>	XGBoost menghasilkan akurasi prediksi terbaik dibandingkan model lain dalam memprediksi permintaan dan <i>lead time</i> , serta mampu meningkatkan efektivitas pengambilan keputusan dalam sistem persediaan sektor kesehatan.
3	Hidayat & Sulistiyono (2025, JPTI)	Analisis Performa Algoritma XGBoost, GRU, dan Prophet dalam Peramalan Penjualan Obat untuk Optimasi Rantai Pasok Farmasi	XGBoost menunjukkan performa terbaik dengan nilai RMSE sebesar 4,02 dan MAPE sebesar 4,35%, sehingga lebih unggul dalam menangani data penjualan obat yang bersifat fluktuatif.
4	Dzul Asmi Alhamdi dkk. (2023, Indonesian Journal of Computer Science)	Peramalan Kebutuhan Obat Menggunakan XGBoost Studi Kasus pada Rumah Sakit XYZ	Model XGBoost digunakan untuk peramalan kebutuhan obat berbasis <i>time series</i> dengan hasil evaluasi menggunakan RMSE dan MAE. Model menunjukkan performa yang lebih baik pada kategori obat tertentu, namun masih memerlukan peningkatan untuk hasil yang lebih optimal.
5	Fourkiotis & Tsadiras (2024, MDPI Forecasting)	<i>Applying Machine Learning and Statistical Forecasting Methods for Enhancing Pharmaceutical Sales Predictions</i>	XGBoost menghasilkan nilai MAPE terendah dibandingkan metode lain, serta mampu menangkap pola musiman dan fluktuasi permintaan pada data farmasi.
6	Sousa (2024, IEETA (of UA.))	<i>Predictive Modeling of Pharmaceutical Stock Demand Using Machine Learning: A Comprehensive Case Study</i>	Model XGBoost menunjukkan performa tinggi dengan nilai RMSE yang rendah dan mampu memodelkan pola permintaan yang kompleks termasuk <i>seasonality</i> dan variasi permintaan.
7	Menebo (2025)	<i>Leveraging Big Data, Weather Insights, and the XGBoost ML Model to Better Forecast Medication Demand and Manage Shortages</i>	XGBoost menghasilkan nilai koefisien determinasi (R^2) sebesar 0,80 dan mampu mengakomodasi pengaruh faktor eksternal terhadap fluktuasi permintaan.
8	Winurputra & Ratnawati (2025, JTIK)	Peramalan Penjualan Produk Menggunakan <i>Extreme Gradient Boosting</i> (XGBoost) dan Kerangka Kerja CRISP-DM untuk Pengoptimalan Manajemen Persediaan (Studi Kasus: UB Mart)	XGBoost mampu meningkatkan akurasi peramalan dengan nilai MAE sebesar 11,58 serta membantu dalam pengambilan keputusan pengendalian persediaan.

No	Nama	Judul	Hasil
9	Ridwan & Ahsan (2024, JRI)	Penentuan <i>Reorder Point</i> dan <i>Safety Stock</i> pada Consumable Material Berdasarkan Peramalan Menggunakan Artificial Neural Network	Model ANN mampu menghasilkan nilai ROP dan <i>safety stock</i> yang optimal berdasarkan hasil peramalan, sehingga meningkatkan efisiensi sistem persediaan.
10	Avinash dkk. (2024, JUTISI)	<i>Analisis Perbandingan Algoritma Machine Learning untuk Forecasting Persediaan Produk Barang Pokok</i>	Metode SARIMA menunjukkan performa terbaik dengan nilai MAPE di bawah 1% setelah dilakukan <i>preprocessing data</i> , menekankan pentingnya pemilihan metode yang sesuai.
11	Wardhana dkk. (2022, Jurnal RESTI)	<i>Gradient Boosting Machine, Random Forest dan Light GBM untuk Klasifikasi Kacang Kering</i>	Metode boosting menunjukkan performa tinggi dengan akurasi mencapai 99% pada data pelatihan, menunjukkan keunggulan pendekatan <i>tree-based learning</i> .
12	Liu dkk. (2025, Journal of Digital Economy)	<i>A machine learning approach to inventory stockout prediction</i>	Model <i>machine learning</i> mampu meningkatkan akurasi prediksi stockout dengan memanfaatkan data skala besar serta variabel permintaan jangka pendek, sehingga membantu dalam pengambilan keputusan pengendalian persediaan.

Sumber : Sumber: Hasil studi literatur peneliti (2026)

Berdasarkan penelitian terdahulu yang telah disajikan, dapat diketahui bahwa pendekatan *machine learning* banyak digunakan dalam meningkatkan akurasi peramalan permintaan, terutama pada data yang bersifat fluktuatif. Algoritma XGBoost secara konsisten menunjukkan performa yang unggul dibandingkan metode lain, baik dalam konteks peramalan permintaan umum maupun pada sektor farmasi.

Selain itu, beberapa penelitian juga menunjukkan bahwa hasil peramalan dapat dimanfaatkan dalam pengambilan keputusan pengendalian persediaan, seperti penentuan *safety stock* dan *reorder point*. Hal ini menunjukkan adanya keterkaitan antara akurasi peramalan dengan efektivitas sistem persediaan.

Lebih lanjut, penelitian oleh Liu et al. (2025) menunjukkan bahwa pendekatan *machine learning* juga efektif dalam memprediksi risiko *stockout*

secara langsung, sehingga dapat menjadi dasar dalam pengambilan keputusan pengendalian persediaan yang lebih proaktif.

Namun demikian, penelitian yang secara khusus mengintegrasikan hasil prediksi berbasis XGBoost dengan perhitungan *safety stock* dan *reorder point* secara dinamis pada konteks laboratorium *Quality Control* masih relatif terbatas. Selain itu, penggunaan data dalam penelitian sebelumnya umumnya masih bersifat agregat, seperti data bulanan atau mingguan, sehingga kurang mampu menangkap fluktuasi permintaan harian yang lebih dinamis.

Di sisi lain, sebagian besar penelitian terdahulu masih memiliki keterbatasan dalam aspek pengendalian persediaan yang diterapkan. Beberapa penelitian seperti Barghi & De (2025), Wagaw & Demisse (2025), serta Fourkiotis & Tsadiras (2024) lebih berfokus pada peningkatan akurasi model peramalan tanpa mengaitkannya secara langsung dengan kebijakan operasional persediaan. Sementara itu, penelitian seperti Ridwan & Ahsan (2024) telah mengintegrasikan peramalan dengan perhitungan *reorder point* dan *safety stock*, namun pendekatan yang digunakan masih bersifat statis dan belum mempertimbangkan dinamika permintaan secara real-time.

Selain itu, sebagian penelitian masih menggunakan pendekatan konvensional dalam pengendalian persediaan, seperti penggunaan rata-rata historis dalam perhitungan ROP, sehingga kurang mampu mengakomodasi fluktuasi permintaan yang tinggi. Pendekatan ini menjadi kurang optimal terutama pada sistem dengan variabilitas tinggi dan kebutuhan yang bersifat dinamis.

Lebih lanjut, penelitian terdahulu juga belum banyak mempertimbangkan karakteristik produk yang bersifat *perishable*, di mana terdapat batasan umur simpan yang mempengaruhi nilai dan tingkat permintaan produk. Hal ini menyebabkan pendekatan pengendalian persediaan yang digunakan menjadi kurang optimal, karena tidak mempertimbangkan risiko kedaluwarsa (*expiration*) dan pemborosan (*waste*) secara eksplisit. Padahal,

pada material dengan karakteristik *fast-moving* dan *perishable* secara bersamaan, sistem persediaan memerlukan pendekatan yang lebih adaptif dan responsif terhadap perubahan permintaan serta keterbatasan umur simpan.

Oleh karena itu, penelitian ini memberikan kontribusi dengan mengintegrasikan model peramalan berbasis XGBoost dengan perhitungan *safety stock* dan *reorder point* (ROP) yang bersifat dinamis, menggunakan data historis permintaan harian. Pendekatan ini diharapkan mampu menghasilkan sistem pengendalian persediaan yang lebih adaptif, akurat, serta relevan dengan kondisi operasional nyata pada laboratorium *Quality Control*.


2.3 Kerangka teori atau konsep

2.3.1 Pengertian kerangka konseptual

Kerangka konseptual merupakan suatu model atau gambaran yang menjelaskan hubungan antara konsep atau variabel yang digunakan dalam penelitian. Menurut Sugiyono (2023), kerangka konseptual adalah sintesis dari teori-teori yang digunakan untuk menjelaskan hubungan antar variabel sehingga dapat memberikan arah dalam pelaksanaan penelitian. Selain itu, Sekaran (2006) menyatakan bahwa kerangka konseptual merupakan model konseptual yang menggambarkan hubungan logis antara variabel-variabel yang telah diidentifikasi dalam penelitian.

Berdasarkan definisi tersebut, kerangka konseptual dalam penelitian ini digunakan untuk menggambarkan keterkaitan antara data historis permintaan, metode prediksi berbasis *machine learning*, serta keputusan pengendalian persediaan yang dihasilkan. Penelitian ini tidak berfokus pada hubungan kausal seperti pada regresi, melainkan pada alur proses yang menunjukkan bagaimana data diolah menjadi dasar pengambilan keputusan dalam sistem persediaan.

2.3.2 Diagram kerangka konseptual



Gambar 2.1 Kerangka Konseptual Penelitian

Sumber : Hasil Rancangan Peneliti (2026)

2.3.3 Penjelasan kerangka konseptual

Kerangka konseptual dalam penelitian ini disusun berdasarkan keterkaitan antara teori manajemen persediaan, peramalan permintaan, serta penerapan metode berbasis *machine learning*. Penelitian ini berangkat dari *grand theory* yaitu manajemen persediaan (*inventory management*) dan manajemen rantai pasok (*supply chain management*), yang menekankan pentingnya menjaga keseimbangan antara ketersediaan stok dan efisiensi biaya dalam sistem operasional.

Selanjutnya, pada tingkat *middle theory*, konsep pengendalian persediaan (*inventory control*) dan *demand forecasting* digunakan untuk menjelaskan mekanisme operasional dalam mengelola persediaan. Peramalan permintaan berperan dalam memperkirakan kebutuhan di masa mendatang, sedangkan pengendalian persediaan berfungsi dalam menentukan kebijakan terkait jumlah dan waktu pemesanan. Keterkaitan keduanya menunjukkan bahwa tingkat akurasi

peramalan akan sangat mempengaruhi efektivitas pengendalian persediaan.

Pada tingkat *applied theory*, penelitian ini mengimplementasikan algoritma *machine learning Extreme Gradient Boosting* (XGBoost) sebagai metode untuk memprediksi permintaan reagen. Pemilihan metode ini didasarkan pada kemampuannya dalam menangkap pola data yang bersifat non-linear dan fluktuatif. Untuk memastikan kualitas hasil prediksi, dilakukan evaluasi menggunakan metrik RMSE dan MAPE guna mengukur tingkat kesalahan model.

Hasil prediksi permintaan kemudian digunakan sebagai dasar dalam perhitungan *safety stock*, *reorder point* (ROP), dan *Economic Order Quantity* (EOQ), yang merupakan parameter utama dalam pengendalian persediaan. Dengan demikian, akurasi hasil prediksi menjadi faktor kunci dalam menghasilkan kebijakan persediaan yang optimal.

Secara keseluruhan, kerangka konseptual ini menunjukkan alur integrasi antara data historis, metode prediksi berbasis *machine learning*, serta penerapan konsep pengendalian persediaan. Integrasi tersebut bertujuan untuk menghasilkan sistem pengendalian persediaan yang lebih adaptif dan berbasis data, sehingga mampu mengoptimalkan ketersediaan reagen serta meminimalkan risiko *stockout*, *overstock*, dan risiko kedaluwarsa (*expiration cost*) dalam operasional laboratorium *Quality Control*.

Untuk memperjelas alur tersebut secara lebih sistematis, kerangka konseptual ini juga dapat dijelaskan menggunakan pendekatan *Input–Process–Output–Outcome* (IPOO). Pada tahap *input*, penelitian ini menggunakan data historis permintaan reagen laboratorium *Quality Control* yang bersifat harian. Data tersebut menjadi dasar dalam mengidentifikasi pola fluktuasi permintaan.

Selanjutnya, pada tahap *process*, dilakukan pengolahan data yang meliputi *preprocessing* untuk memastikan kualitas data, pemodelan menggunakan algoritma XGBoost, serta evaluasi model menggunakan metrik RMSE dan MAPE untuk mengukur tingkat akurasi prediksi.

Tahap berikutnya yaitu *output*, berupa nilai prediksi permintaan reagen yang kemudian digunakan dalam perhitungan parameter pengendalian persediaan, yaitu *safety stock* dan *reorder point* (ROP) serta EOQ yang bersifat dinamis.

Adapun *outcome* dari penelitian ini adalah peningkatan efektivitas pengendalian persediaan yang ditunjukkan melalui penurunan frekuensi *stockout*, *overstock*, serta penurunan risiko kedaluwarsa (*expiration cost*), sehingga mampu meningkatkan efisiensi biaya persediaan secara keseluruhan.

. Dengan demikian, kerangka konseptual ini tidak hanya menggambarkan hubungan antar konsep, tetapi juga menunjukkan bagaimana integrasi antara peramalan berbasis *machine learning* dan pengendalian persediaan dapat memberikan solusi yang optimal dalam sistem persediaan.