



PUBLISHER: <https://journal.adlermanurungpress.com/>

DOI: <https://doi.org/10.63607/jcmb.v14i1>

ANALISIS LITERATUR TENTANG OPTIMALISASI PORTFOLIO INVESTOR INSTITUSI

Susanti Purwaningsih^{1*}, Adler Haymans Manurung²

¹Fakultas Doktor Manajemen dan Bisnis IPB University, Bogor

²Universitas Bhayangkara Jakarta Raya

Email: susantipurwaningsih@apps.ipb.ac.id^{1*}, adler.manurung@dsn.ubharajaya.ac.id²

Alamat: Gedung SB IPB, Jalan Pajajaran Kota Bogor +62 251 8313813

Korespondensi Penulis: susantipurwaningsih@apps.ipb.ac.id

Abstrak

Penelitian ini bertujuan untuk menyajikan tinjauan sistematis terhadap perkembangan teori optimalisasi portofolio yang membentuk dasar bagi pengambilan keputusan investasi oleh investor institusi. Dengan menggunakan metode Systematic Literature Review (SLR) dengan pendekatan PRISMA dan didukung perangkat lunak Zotero dan Vosviewer, penelitian ini menganalisis 33 artikel dari basis data Scopus, JSTOR, dan Web of Science yang diterbitkan antara 2015–2025. Hasil SLR menunjukkan bahwa teori portofolio institusional berkembang dalam empat fase. Fase pertama adalah fondasi teori efisiensi (Markowitz, Sharpe, Lintner, Mossin, Ross). Fase kedua berfokus pada penerapan praktis dan bukti empiris yang menegaskan bahwa investor institusional tidak beroperasi dalam kondisi pasar frictionless dan bebas kendala. Fase ketiga didorong oleh model ALM dan regulasi prudensial yang mengubah frontier efisien teoretis menjadi institutional feasible frontier (IFF). Fase keempat adalah revolusi digital yang memperkenalkan Forecast-Then-Optimize (FTO), deep learning, reinforcement learning, dan hybrid-AI model sebagai alat prediksi risiko dan return.

Secara keseluruhan, literatur teoretis menunjukkan bahwa optimalisasi portofolio institusional bukan sekadar persoalan return–risk, melainkan persoalan multidimensi. Teori-teori baru menunjukkan bahwa frontier institusional hampir selalu berada di bawah

frontier Markowitz akibat adanya natural constraints. Studi ini berlanjut dengan agenda penelitian teoretis masa depan, termasuk perlunya teori portofolio institusional untuk pasar berkembang, model AI interpretatif, dan teori efisiensi yang kompatibel dengan regulasi nasional.

Kata Kunci: portofolio institusional, Modern Portfolio Theory, machine learning, institutional constraints, PRISMA.

Abstract

This study aims to present a systematic review of the development of portfolio optimization theory that forms the basis for investment decision-making by institutional investors. This study using a Systematic Literature Review (SLR) with the PRISMA (Preferred Reporting Items for Systematic Review and Meta Analysis) approach, this study analyzes 33 articles from Scopus, JSTor, and Web of Science published between 2015 and 2025. The SLR results show that institutional portfolio theory developed in four stages. The first stage was the foundation of efficiency theory (Markowitz, Sharpe, Lintner, Mossin, and Ross). The second stage focused on practical applications and empirical evidence confirming that institutional investors do not operate in frictionless and unconstrained market conditions. The third stage was driven by ALM models and prudential regulation, transforming the theoretical efficient frontier into the institutional feasible frontier (IFF). The fourth stage was the digital revolution, introducing Forecast-Then-Optimize (FTO), deep learning, reinforcement learning, and hybrid-AI models as risk and return prediction tools.

Overall, the theoretical literature shows that optimizing institutional portfolios is not simply a return-risk problem, but rather a multidimensional one. New theories suggest that the institutional frontier almost always lies below the Markowitz frontier due to natural constraints. This study concludes with a theoretical research agenda for future research, including the need for institutional portfolio theory for emerging markets, interpretive AI models, and efficiency theory compatible with national prudential regulations.

Keywords: institutional portfolio, Modern Portfolio Theory, machine learning, institutional constraints, PRISMA.

PENDAHULUAN

Optimalisasi portofolio merupakan pilar utama dalam keuangan modern dan telah mengalami perkembangan metodologis yang sangat signifikan sejak diperkenalkannya

teori portofolio oleh Markowitz (1952). Konsep efficient frontier yang diperkenalkannya menjadi tonggak sejarah dalam teori keuangan modern. Teori ini kemudian dilengkapi oleh *Capital Asset Pricing Model* (CAPM) yang dikembangkan oleh Sharpe (1964), Lintner (1965), dan Mossin (1966), yang menjelaskan hubungan antara risiko sistematis (*beta*) dan *expected return*. Namun, sejumlah kritik muncul terkait asumsi fundamental CAPM: distribusi return normal, tidak ada friksi pasar, pasar efisien, serta tidak ada biaya transaksi. Empirically, CAPM tidak dapat menjelaskan fenomena anomali pasar dan perilaku asset pricing, terutama di pasar negara berkembang. Model *Arbitrage Pricing Theory* (APT) oleh Ross (1976) memperluas kerangka CAPM dengan mengakomodasi multi-faktor risiko. Pendekatan ini lebih fleksibel dan tidak bergantung pada portofolio pasar, namun tetap mengandalkan asumsi rasionalitas investor dan struktur pasar tertentu. Dalam berbagai penelitian empiris, teori-teori klasik ini menunjukkan kinerja yang terbatas dalam kondisi *tail risk* dan volatilitas ekstrem.

Mulai tahun 1990-an hingga 2000-an, fokus literatur bergeser pada risiko non-linear dan downside-risk. Rockafellar dan Uryasev (2000) memperkenalkan *Conditional Value at Risk* (CVaR) sebagai ukuran risiko tail yang lebih robust dibandingkan varians. VaR dan CVaR menjadi standar industri terutama di sektor perbankan dan manajemen aset. Seiring integrasi pasar global, Bekaert dan Harvey (2007) menunjukkan bahwa risiko likuiditas dan return di pasar berkembang sangat berbeda dengan asumsi klasik, sehingga membutuhkan pendekatan lebih adaptif.

Pada saat yang sama, investor institusi yaitu dana pensiun, perusahaan asuransi, bank, dan *sovereign wealth funds* mengalami perubahan besar akibat regulasi *prudensial*, *aging population*, dan volatilitas jangka panjang. Bikker dan Broeders (2010) menunjukkan bahwa investor institusi tidak beroperasi pada *efficient frontier* Markowitz, melainkan pada *institutional feasible frontier* yang dibatasi oleh regulasi, likuiditas, solvency ratio, maturity mismatch, dan liability driven investment (LDI). Campbell dan Viceira (2002) menegaskan pentingnya strategi investasi jangka panjang yang mempertimbangkan risiko intertemporal. Gomes dan Michaelides (2021) memperluas hal ini dengan memasukkan kendala likuiditas dan regulasi ke dalam model *portfolio life cycle*. Penelitian Jang, Clare, dan Owadally (2024) memberikan bukti bahwa risiko longevity dan stokastisitas kewajiban membuat optimalisasi portofolio institusi semakin kompleks.

Pendekatan menggunakan Systematic Literature Review (SLR) dipilih untuk menyusun temuan-temuan empiris dan konseptual terkait hubungan antara teori

keunggulan sumber daya, strategi pemasaran, dan strategi bisnis. Metode SLR memungkinkan peneliti mengidentifikasi pola konseptual dan hubungan antarvariabel yang tersebar di berbagai konteks industri dan geografis (Varadarajan, 2020; Popa et al., 2023; Sahi et al., 2022).

Pada dekade terakhir, digitalisasi dan perkembangan kecerdasan buatan membawa perubahan radikal dalam optimalisasi portofolio. *Deep learning*, seperti LSTM (Fischer & Krauss, 2018) dan *neural networks* (Zhang et al., 2020), memungkinkan prediksi pasar yang lebih akurat. *Reinforcement Learning (RL)* dan *Deep Reinforcement Learning (DRL)*, seperti PPO, DDPG, A3C, dan actor-critic models, memungkinkan kebijakan alokasi aset dinamis yang mampu beradaptasi terhadap perubahan kondisi pasar secara real-time. Penelitian Jeon et al. (2025), Broda et al. (2025), dan Wu & Hargreaves (2023) menunjukkan bahwa DRL dapat mengungguli metode konvensional.

Meskipun demikian, terdapat gap besar dalam literatur *Artificial Intelligent (AI)*, yaitu tidak adanya integrasi yang memadai antara model kecerdasan buatan dan kendala regulatif institusi. Hal ini penting karena portofolio institusi tidak hanya bertujuan memaksimalkan return, tetapi juga menjaga stabilitas jangka panjang, solvency ratio, dan kemampuan memenuhi kewajiban. Oleh karena itu, penelitian SLR ini menjadi relevan untuk membuat peta evolusi teori dan mengidentifikasi peluang pengembangan penelitian.

Berdasarkan uraian teori dan penelitian sebelumnya, dapat diidentifikasi beberapa rumusan masalah dalam penelitian ini yaitu bagaimana karakteristik aset institusional pada berbagai kondisi pasar dengan melihat frontier portofolio yang dihasilkan melalui metode optimasi konvensional (Markowitz, CVaR, MAD) dibandingkan dengan metode Machine Learning serta mengukur seberapa besar perbedaan (Efficiency Gap/ ΔE) antara frontier efisiensi teoretis MPT dan Institutional dimana gap ini belum pernah diukur sebelumnya baik dalam penelitian Indonesia maupun internasional sehingga menjadi bagian terkuat dari novelty penelitian ini. Kemudian pertanyaan selanjutnya adalah Model optimasi seperti apa yang paling efisien dan paling realistis diterapkan untuk pengelolaan dana pensiun Indonesia di masa mendatang apakah metode konvensional atau *machine learning*?

Tujuan penelitian ini dirumuskan untuk menjawab permasalahan serta memperluas kontribusi teoretis dan praktis terhadap literatur portofolio institusional, terutama dalam konteks dana pensiun Indonesia sejalan dengan teori portofolio modern (Markowitz,

1952), teori risiko–return (Sharpe, 1964), stochastic ALM (Jang et al., 2024), institutional constraints (Bikker & Broeders, 2010; Davis & Steil, 2001), serta pendekatan *machine learning* terkini (Li et al., 2025; Zhang et al., 2023), maka dapat dilakukan pengembangan model optimasi portofolio insvestor institusi dengan menggunakan model optimisasi portofolio yang memadukan pendekatan konvensional dengan pendekatan berbasis *machine learning* untuk memperoleh hasil yang adaptif dan akurat.

Penelitian ini memberikan kontribusi teoretis terhadap pengembangan literatur mengenai optimalisasi portofolio investasi institusional di negara berkembang. Integrasi teori Markowitz (1952) dengan pendekatan *machine learning* (Li et al., 2025) menunjukkan arah baru dalam penelitian keuangan modern yang memadukan aspek matematis, statistik, dan teknologi kecerdasan buatan. Secara praktis, hasil penelitian ini juga dapat menjadi referensi bagi lembaga pengelola dana investasi untuk meninjau kembali kebijakan alokasi aset investasi yang selama ini cenderung konservatif. Dengan model empiris berbasis data internal dan IDX maka institusi pengelola dana dapat mengadopsi pendekatan kuantitatif yang rasional dalam menentukan proporsi portofolio investasinya.

KERANGKA TEORI

Systematic Literature Review (SLR) dalam penelitian ini menjadi metode untuk mengeksplorasi dan menyusun temuan-temuan terkait Kerangka teori optimalisasi portofolio dalam SLR ini mengacu pada empat fondasi utama: (1) teori klasik portofolio, (2) teori risiko modern dan *downside risk*, (3) teori kendala kelembagaan (*institutional constraints*), dan (4) pendekatan modern berbasis kecerdasan buatan dan *deep reinforcement learning*.

SLR dipilih karena mampu menyajikan kajian pustaka secara sistematis, transparan, dan dapat direplikasi, yang bertujuan untuk meminimalkan bias peneliti dan meningkatkan objektivitas temuan (Priharsari, 2022). SLR merupakan bentuk khusus dari studi kepustakaan yang tidak hanya meninjau secara naratif, tetapi juga menerapkan proses pencarian yang eksplisit dan terstruktur. Keunggulan metode ini terletak pada kemampuannya untuk mengurangi subjektivitas dalam penyaringan literatur, melalui tahapan yang ketat seperti penentuan kata kunci, kriteria inklusi dan eksklusi, serta proses seleksi multi-tahap yang dapat ditelusuri (Watajdid et al., 2021). Meski demikian, sebagaimana dikemukakan oleh Priharsari (2022), peran peneliti sebagai instrumen

utama dalam penilaian literatur tetap menyisakan potensi bias interpretatif yang tidak sepenuhnya dapat dihilangkan, meskipun dapat dikendalikan melalui prosedur yang terstandarisasi.

Tahapan SLR dalam penelitian ini mengacu pada kerangka kerja PRISMA (*Preferred Reporting Items for Systematic Review and Meta Analysis*). PRISMA dipilih karena merupakan standar internasional dalam menjalankan tinjauan pustaka sistematis, yang menekankan transparansi prosedur pencarian, seleksi, dan sintesis literatur. Dengan pendekatan tersebut, penelitian ini memastikan bahwa seluruh proses penelaahan literatur dilakukan secara sistematis dan dapat dipertanggungjawabkan secara ilmiah.

Proses pencarian literatur dilakukan dengan menelusuri beberapa basis data ilmiah bereputasi, seperti JSTOR, Scopus, dan Web of Science. Selain itu, untuk kepentingan peninjauan karya klasik yang menjadi landasan teori optimasi portofolio, peneliti juga mengakses repositori jurnal seperti *The Journal of Finance*, *Econometrica*, dan *Review of Economics and Statistics*. Artikel seminal seperti karya Markowitz (1952), Sharpe (1964), Litner (1965), Mossin (1966) dan Ross (1976) dimasukkan secara khusus karena kontribusinya yang fundamental bagi evolusi teori portofolio modern. Pencarian literatur dilakukan dengan memanfaatkan kata kunci yang dirancang melalui kombinasi *Boolean logic*, yang menghubungkan istilah berkaitan dengan optimasi portofolio, manajemen risiko, investor institusional, serta teknik kecerdasan buatan.

Kata kunci yang digunakan meliputi istilah inti seperti “portfolio optimization”, “institutional portfolio”, “Modern Portfolio Theory”, dan untuk menjangkau literatur terkait pendekatan kecerdasan buatan, digunakan kata kunci seperti “machine learning portfolio optimization”, “machine learning”, dan “reinforcement learning asset allocation”. Pemilihan kata kunci yang luas ini bertujuan untuk menangkap seluruh spektrum perkembangan teori portofolio dari tahun 1950-an hingga 2025.

Proses penelusuran literatur menghasilkan sekitar 295 artikel. Setelah duplikasi dihapus dan kesesuaian awal dilihat berdasarkan judul dan abstrak, artikel yang tersisa adalah 172. Tahap berikutnya adalah peninjauan kelayakan (*eligibility*) melalui pembacaan penuh untuk menilai relevansi substantif dan metodologis artikel. Pada tahap ini peneliti menilai apakah artikel memiliki kontribusi teoritis yang jelas, menyajikan model matematis atau empiris yang dapat dievaluasi, serta relevan dengan investor institusional seperti dana pensiun. Proses tersebut menyisakan 105 artikel. Setelah penilaian kualitas, yang mencakup reputasi jurnal, kontribusi ilmiah, kompleksitas

metodologi, serta kesesuaian topik dengan fokus penelitian, diperoleh 33 artikel final yang digunakan dalam sintesis data. Artikel-artikel ini mencakup karya klasik, karya empiris modern, serta artikel frontier dalam bidang *machine learning*.

Tahapan selanjutnya adalah penilaian kualitas artikel menggunakan *quality assessment framework*. Penilaian dilakukan dengan menimbang lima aspek utama. Pertama, kejelasan penyajian model teoritis atau matematis, termasuk asumsi dasar, formulasi model, dan teknik estimasi. Kedua, validitas empiris dari penelitian, terutama apakah artikel menyertakan pengujian data *out-of-sample* atau pendekatan yang mencerminkan kondisi pasar riil. Ketiga, relevansi literatur bagi investor institusional, khususnya terkait regulasi, kendala likuiditas, ALM, dan horizon investasi jangka panjang. Keempat, kontribusi teoretis atau metodologis terhadap perkembangan literatur. Kelima, kekuatan metodologis, baik yang berbasis optimasi klasik, risiko modern seperti CVaR, maupun kecerdasan buatan seperti LSTM dan DRL.

Untuk menjaga transparansi dan replikabilitas penelitian, seluruh artikel yang lolos seleksi kemudian dibuat kode menggunakan *extraction matrix* yang mencatat informasi utama seperti tahun publikasi, tujuan penelitian, metode, variabel yang digunakan, ukuran risiko, jenis algoritma, konteks empiris, serta temuan dan kontribusi utama. Proses ekstraksi data ini penting agar sintesis literatur dapat dilakukan secara konsisten dan memungkinkan analisis tematik yang mendalam. Sintesis data dilakukan dalam dua pendekatan. Pertama, sintesis evolusioner (*chronological synthesis*) untuk memetakan perkembangan teori dari *mean variance*, CAPM, APT, CVaR, ALM, hingga metode kecerdasan buatan. Pendekatan ini menunjukkan bagaimana teori portofolio berkembang secara linier maupun melompat, serta bagaimana masing-masing era teori merespons kelemahan pendekatan sebelumnya. Kedua, sintesis berbasis kluster tematik untuk mengelompokkan literatur dalam lima kategori besar, yaitu teori klasik, risiko modern, investor institusi dan ALM, ESG–makro dan keterhubungan pasar, serta pendekatan kecerdasan buatan modern. Pengelompokan ini memungkinkan peneliti mengidentifikasi kekuatan, kelemahan, tren metodologis, dan gap penelitian.

PRISMA digunakan untuk menggambarkan alur seleksi literatur mulai dari identifikasi hingga sintesis akhir. Pada tahap identifikasi ditemukan 295 artikel, kemudian setelah penyaringan dan evaluasi, artikel yang memenuhi syarat menjadi 33 artikel. Diagram ini tidak hanya memberikan panduan visual mengenai proses seleksi, tetapi juga menunjukkan bahwa penelitian telah mengikuti standar SLR yang ketat dan

transparan. Metode penelitian ini berfungsi untuk menjamin bahwa hasil kajian benar-benar berdiri di atas landasan ilmiah yang kuat dan proses yang terstandarisasi. Dengan menerapkan pendekatan PRISMA, menggunakan basis data bereputasi, menerapkan kriteria seleksi yang ketat, serta melakukan penilaian kualitas secara sistematis, penelitian ini menghasilkan sintesis literatur yang komprehensif, valid, dan relevan bagi pengembangan metode optimasi portofolio, khususnya dalam konteks perubahan signifikan pada dinamika pasar keuangan global dan integrasi kecerdasan buatan dalam pengambilan keputusan investasi. Metode yang digunakan juga memastikan bahwa SLR ini tidak hanya berkontribusi secara akademik tetapi juga dapat menjadi referensi praktis bagi pengambil kebijakan, investor institusional, serta peneliti yang ingin mengembangkan pendekatan optimasi portofolio generasi berikutnya.

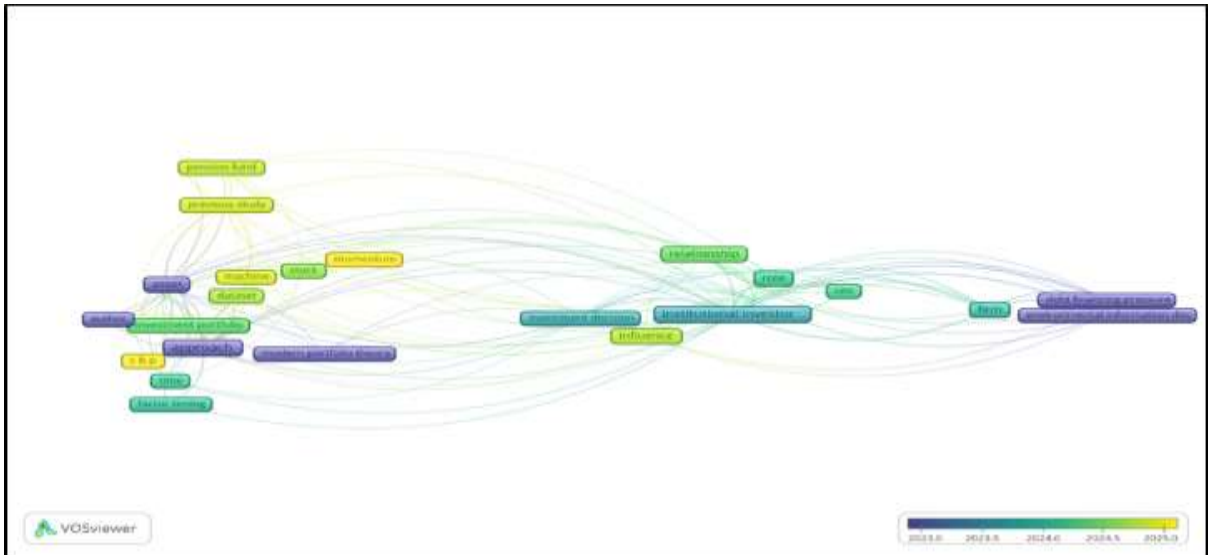
PEMBAHASAN

Hasil SLR menunjukkan bahwa teori portofolio institusional berkembang dalam empat fase. Fase pertama adalah fondasi teori efisiensi (Markowitz, Sharpe, Lintner, Mossin, Ross). Fase kedua berfokus pada penerapan praktis dan bukti empiris yang menegaskan bahwa investor institusional tidak beroperasi dalam kondisi pasar *frictionless* dan bebas kendala. Fase ketiga didorong oleh model ALM dan regulasi prudensial yang mengubah *frontier efisien* teoretis menjadi *institutional feasible frontier* (IFF). Fase keempat adalah revolusi digital yang memperkenalkan *Forecast Then Optimize (FTO)*, *deep learning*, *reinforcement learning*, dan *hybrid AI model* sebagai alat prediksi risiko dan return.

Hasil visualisasi bibliometrik menggunakan VOSviewer pada Gambar 1 memperlihatkan bahwa investor institusi merupakan simpul sentral yang memiliki keterkaitan erat dengan berbagai elemen investasi seperti *investment decision*, *investment portfolio*, *momentum*, *timing*, *machine learning*. Teori optimalisasi portofolio telah berevolusi dari pendekatan linear dan asumsi pasar sempurna menjadi pendekatan multi-faktor, bertingkat, dan berbasis kecerdasan buatan. Teori klasik Markowitz (1952), Sharpe (1964), Litner (1965), Mossin (1966) dan Ross (1976) masih menjadi fondasi, namun tidak mencerminkan kompleksitas pasar modern dan realitas investor institusi.

Hubungan ini menunjukkan bahwa *machine learning* adalah bagian optimalisasi portofolio yang memengaruhi tingkat return. Keterhubungan antara Temuan ini sejalan

dengan Model risiko modern seperti CVaR (Rockafellar & Uryasev, 2000) memberikan alat ukur yang lebih akurat dalam menghadapi risiko ekstrem. Sementara itu, literatur institutional constraints (Bikker & Broeders, 2010; Campbell & Viceira, 2002; Gomes & Michaelides, 2021) menunjukkan bahwa investor institusi beroperasi dalam ruang keputusan yang jauh lebih terbatas daripada asumsi teori klasik. Selain itu, perkembangan instrumen keuangan seperti ESG assets (Arouri et al., 2025) mengubah cara investor mendiversifikasi risiko.

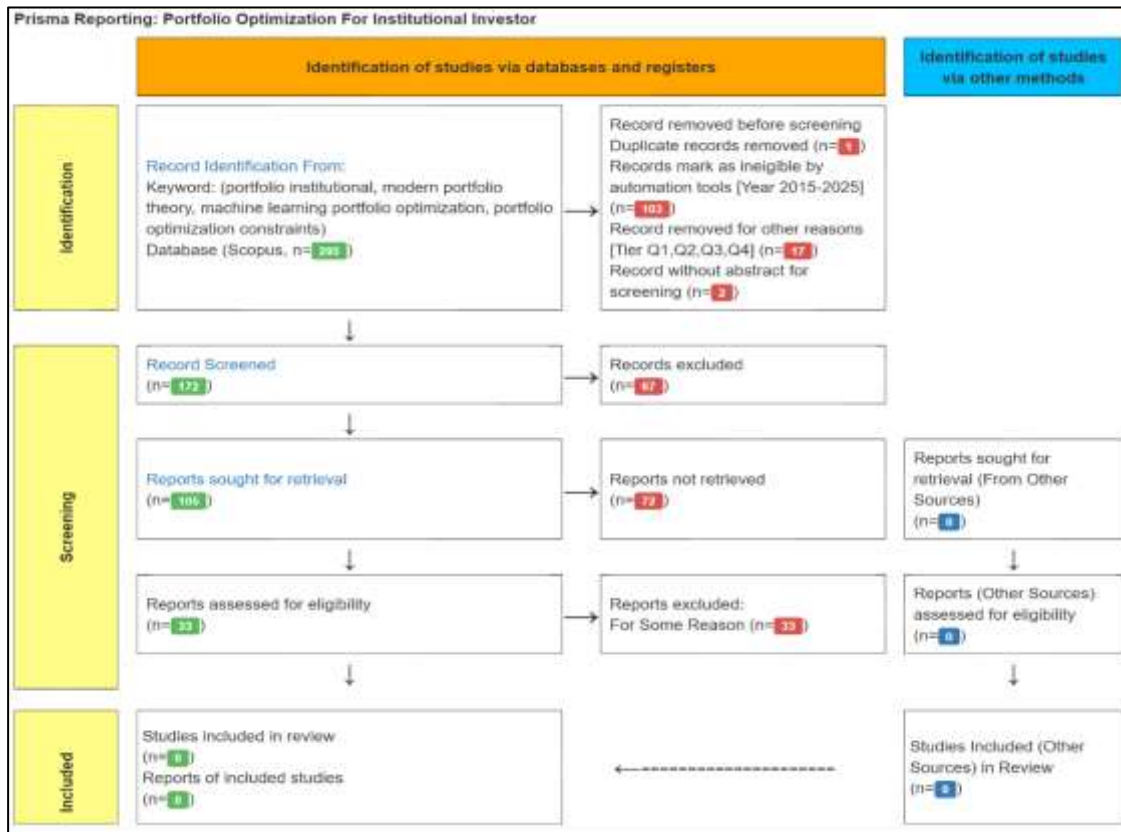


Gambar 1. Pemetaan Penelitian Optimalisasi Portofolio Investor Institusi Menggunakan tools VOSviewer
Sumber: diolah penulis (2025)

Proses *Systematic Literature Review* (SLR) yang digambarkan melalui diagram PRISMA pada Gambar 2 menunjukkan alur seleksi sistematis terhadap literatur yang relevan. Proses penelusuran literatur menghasilkan sekitar 295 artikel. Setelah duplikasi dihapus dan kesesuaian awal dilihat berdasarkan judul dan abstrak, artikel yang tersisa adalah 172. Tahap berikutnya adalah peninjauan kelayakan (*eligibility*) melalui pembacaan penuh untuk menilai relevansi substantif dan metodologis artikel. Pada tahap ini peneliti menilai apakah artikel memiliki kontribusi teoritis yang jelas, menyajikan model matematis atau empiris yang dapat dievaluasi, serta relevan dengan investor institusional seperti dana pensiun. Proses tersebut menyisakan 105 artikel.

Selanjutnya, 105 artikel dievaluasi untuk menentukan kelayakan isi berdasarkan topik dan kontribusi ilmiahnya. Pada tahap ini, sebanyak 72 artikel dikeluarkan karena berbagai alasan, seperti tidak relevan dengan topik (*unrelated subject area*), penggunaan kata kunci yang tidak sesuai, bukan merupakan hasil riset primer, serta publikasi yang

belum final. Hasil akhir dari proses seleksi ini menghasilkan 33 artikel ilmiah yang memenuhi semua kriteria untuk dianalisis lebih lanjut yang mencakup karya klasik, karya empiris modern, serta artikel frontier dalam bidang *machine learning*.



Gambar 2. PRISMA Diagram Optimalisasi Portfolio Investor Institusi
 Sumber : diolah penulis (2025)

Artikel-artikel yang terpilih dalam kajian ini secara umum menunjukkan bahwa Systematic Literature Review menyimpulkan bahwa teori klasik, yang dimulai dari karya monumental Markowitz (1952), tetap menjadi fondasi bagi seluruh pendekatan optimasi portofolio. Konsep *mean variance*, efisiensi, dan diversifikasi masih sangat relevan hingga saat ini, meskipun telah mengalami banyak perluasan. Teori-teori berikutnya seperti CAPM dari Sharpe (1964), Litner (1965), Mossin (1966) dan APT dari Ross (1976), menambahkan struktur risiko sistematis dan multi-faktor yang memberikan pemahaman lebih kaya mengenai determinan return. Namun, teori klasik dan linier ini tidak mampu sepenuhnya menangkap dinamika pasar yang non-linear, volatilitas ekstrem, distribusi return yang tidak normal, serta interaksi kompleks antar aset.

Perkembangan pasar global dan meningkatnya frekuensi kejadian ekstrem memunculkan kebutuhan terhadap alat pengukuran risiko yang lebih adaptif. Kehadiran

CVaR sebagaimana diformulasikan oleh Rockafellar dan Uryasev (2000) menawarkan pendekatan yang lebih realistis terhadap risiko ekor dan kerugian ekstrem. Model risiko ini sangat penting dalam konteks investor institusional yang memiliki horizon investasi jangka panjang dan menghadapi risiko solvabilitas yang signifikan. Penelitian lanjutan menunjukkan bahwa pendekatan CVaR dan varian risiko modern lainnya lebih cocok untuk menangani lingkungan pasar yang penuh ketidakpastian dan guncangan sistemik.

Selain risiko aset, investor institusional, terutama dana pensiun, juga harus mempertimbangkan risiko kewajiban jangka panjang. Hal inilah yang melahirkan pendekatan *Asset–Liability Management (ALM)*. Campbell dan Viceira (2002) serta Jang, Clare, dan Owadally (2024) menunjukkan bahwa ALM memberikan kerangka yang lebih holistik bagi dana pensiun untuk mengelola portofolio tidak hanya berdasarkan return dan risiko aset, tetapi juga berdasarkan struktur kewajiban, volatilitas suku bunga, dan dinamika demografis. Dengan demikian, pendekatan ALM menjembatani gap antara teori optimasi aset dan kebutuhan operasional lembaga keuangan jangka panjang.

Selanjutnya, perkembangan pesat teknologi data dan komputasi telah mendorong adopsi pendekatan *machine learning (ML)* dan *deep learning (DL)* dalam penelitian portofolio. Studi-studi seperti Fischer dan Krauss (2018) serta Zhang, Zohren, dan Roberts (2020) membuktikan bahwa ML dan DL memiliki kemampuan dalam memprediksi dan menangkap pola non-linear dan struktur kompleks dalam data deret waktu keuangan. Akan tetapi, model prediksi semata tidak cukup untuk mengatasi tantangan pengambilan keputusan dalam kondisi pasar yang dinamis.

Perkembangan mutakhir menghadirkan *deep reinforcement learning (DRL)* sebagai paradigma baru yang menjanjikan. DRL mampu mengembangkan strategi investasi secara end-to-end melalui interaksi berkelanjutan antara agent dan lingkungan pasar. Penelitian oleh He et al., Wu dan Hargreaves (2023), Broda et al. (2025), dan Jeon et al. (2025) menunjukkan bahwa model DRL mampu menyesuaikan kebijakan investasi secara adaptif dan belajar dari perubahan rezim pasar. Pendekatan ini menawarkan kemampuan prediktif sekaligus kemampuan adaptif, dua aspek yang sangat diperlukan dalam pengelolaan portofolio modern.

Meski demikian, terdapat keterbatasan signifikan dari pendekatan ML, DL, dan DRL, terutama terkait interpretabilitas dan integrasi dengan *institutional constraints*. Banyak model bersifat *black box*, sehingga sulit dijelaskan kepada regulator dan pemangku

kepentingan internal. Selain itu, sebagian besar penelitian ML/DRL tidak mengakomodasi kendala regulatif seperti batasan alokasi aset, kewajiban likuiditas, dan larangan short-selling. Padahal dalam konteks investor institusional seperti dana pensiun, kendala-kendala tersebut bersifat wajib dan mendefinisikan ruang keputusan investasi. Hal ini menegaskan bahwa terdapat *efficiency gap* yang substansial antara optimalitas teoritis dan optimalitas aktual yang dapat dicapai di bawah batasan regulatif.

Dalam kerangka yang lebih luas, integrasi ESG menjadi kebutuhan utama dalam pengelolaan portofolio jangka panjang. Meta-analisis oleh Friede, Busch, dan Bassen (2015) menunjukkan bahwa kinerja ESG secara umum berkorelasi positif dengan kinerja keuangan. Selain itu, penelitian Arouri et al. (2025) menyoroti pentingnya keterhubungan aset hijau dengan emas sebagai aset lindung nilai, sehingga memberikan pandangan baru mengenai dinamika portofolio yang berorientasi pada keberlanjutan dan stabilitas jangka panjang.

Berdasarkan Hasil kajian tersebut terangkum dalam sebuah *state of the art* yang disajikan pada Tabel 1.

Tabel 1. *State of the art* Optimalisasi Portfolio Investor Institutsi

Penulis	Judul Artikel	Tahun	Jenis Penelitian	Variabel yang Diteliti
Friede, Busch & Bassen	ESG and Financial Performance	2015	Meta-analisis	ESG, return, kinerja keuangan
Fischer & Krauss	Deep Learning with LSTM for Financial Prediction	2018	Empiris / Machine Learning	LSTM, prediksi harga, return
Zhang et al.	Deep Learning for Portfolio Allocation	2020	Empiris	Fitur pasar, bobot aset
He, Wu & Hargreaves	Deep Reinforcement Learning for Portfolio Optimization	2023	Empiris / DRL	Aksi portofolio, return, risiko
Jang, Clare & Owadally	Stochastic Asset-Liability Management for Pension Funds	2024	Empiris / ALM stokastik	Kewajiban, volatilitas, risiko umur panjang
Arouri, Lahiani & Nguyen	Dynamic Connectedness between Green Bonds, ESG, and Gold	2025	Empiris / Time-series	ESG, green bonds, hedging, volatilitas
Jeon, Lee & Park	RL-Based Dynamic Asset Allocation with Macro & Technical Analysis	2025	Empiris / DRL	Indikator teknikal, indikator makro
Broda, De Nard & Walker	Dynamic Asset Allocation with Reinforcement Learning	2025	Empiris / DRL	Reward, kondisi pasar, risiko

Sumber: diolah penulis (2025)

Penelitian ini menyajikan sebuah *Systematic Literature Review* (SLR) komprehensif yang memetakan perjalanan panjang evolusi teori dan metode optimalisasi portofolio sejak awal kemunculannya pada pertengahan abad ke-20 hingga transformasinya di era digital yang ditandai dengan integrasi *machine learning*, *deep learning*, *reinforcement learning*, serta faktor keberlanjutan dan kendala institusional. Melalui penelusuran sistematis berdasarkan tahapan PRISMA dan analisis mendalam terhadap 35 artikel seminal dan frontier, kajian ini memberikan gambaran menyeluruh mengenai perkembangan paradigma optimasi portofolio dan memberikan landasan konseptual bagi arah pengembangan penelitian di masa mendatang.

Kajian ini menunjukkan bahwa teori klasik, yang dimulai dari karya monumental Markowitz (1952), tetap menjadi fondasi bagi seluruh pendekatan optimasi portofolio. Konsep *mean-variance*, efisiensi, dan diversifikasi masih sangat relevan hingga saat ini, meskipun telah mengalami banyak perluasan. Teori-teori berikutnya seperti CAPM oleh Sharpe (1964), Litner (1965), Mossin (1966) dan teori APT oleh Ross (1976), menambahkan struktur risiko sistematis dan multi-faktor yang memberikan pemahaman lebih kaya mengenai determinan return. Namun, teori klasik dan linier ini tidak mampu sepenuhnya menangkap dinamika pasar yang nonlinear,

volatilitas ekstrem, distribusi return yang tidak normal, serta interaksi kompleks antar aset.

Perkembangan pasar global dan meningkatnya frekuensi kejadian ekstrem memunculkan kebutuhan terhadap alat pengukuran risiko yang lebih adaptif. Kehadiran CVaR sebagaimana diformulasikan oleh Rockafellar dan Uryasev (2000) menawarkan pendekatan yang lebih realistis terhadap risiko ekor dan kerugian ekstrem. Model risiko ini sangat penting dalam konteks investor institusional yang memiliki horizon investasi jangka panjang dan menghadapi risiko solvabilitas yang signifikan. Penelitian lanjutan menunjukkan bahwa pendekatan CVaR dan varian risiko modern lainnya lebih cocok untuk menangani lingkungan pasar yang penuh ketidakpastian dan guncangan sistemik.

Selain risiko aset, investor institusional, terutama dana pensiun, juga harus mempertimbangkan risiko kewajiban jangka panjang. Hal inilah yang melahirkan pendekatan *Asset-Liability Management (ALM)*. Campbell dan Viceira (2002) serta Jang, Clare, dan Owadally (2024) menunjukkan bahwa ALM memberikan kerangka yang lebih holistik bagi dana pensiun untuk mengelola portofolio tidak hanya berdasarkan return dan risiko aset, tetapi juga berdasarkan struktur kewajiban, volatilitas suku bunga, dan dinamika demografis. Dengan demikian, pendekatan ALM menjembatani gap antara teori optimasi aset dan kebutuhan operasional lembaga keuangan jangka panjang.

Selanjutnya, perkembangan pesat teknologi data dan komputasi telah mendorong adopsi pendekatan *machine learning* (ML) dan *deep learning* (DL) dalam penelitian portofolio. Studi-studi seperti Fischer dan Krauss (2018) serta Zhang, Zohren, dan Roberts (2020) membuktikan bahwa ML dan DL memiliki kemampuan dalam memprediksi dan menangkap pola non-linear dan struktur kompleks dalam data deret waktu keuangan. Perkembangan mutakhir menghadirkan *deep reinforcement learning* (DRL) sebagai paradigma baru yang menjanjikan. DRL mampu mengembangkan strategi investasi secara end-to-end melalui interaksi berkelanjutan antara agent dan lingkungan pasar. Penelitian oleh He et al., Wu dan Hargreaves (2023), Broda et al. (2025), dan Jeon et al. (2025) menunjukkan bahwa model DRL mampu menyesuaikan kebijakan investasi secara adaptif dan belajar dari perubahan rezim pasar. Pendekatan ini menawarkan kemampuan prediktif sekaligus kemampuan adaptif, dua aspek yang sangat diperlukan dalam pengelolaan portofolio modern.

Meski demikian, terdapat keterbatasan signifikan dari pendekatan ML, DL, dan DRL, terutama terkait interpretabilitas dan integrasi dengan *institutional constraints*. Banyak model

bersifat *black box*, sehingga sulit dijelaskan kepada regulator dan pemangku kepentingan internal. Selain itu, sebagian besar penelitian ML/DRL tidak mengakomodasi kendala regulatif seperti batasan alokasi aset, kewajiban likuiditas, dan larangan short-selling. Padahal dalam konteks investor institusional seperti dana pensiun, kendala-kendala tersebut bersifat wajib dan mendefinisikan ruang keputusan investasi. Hal ini menegaskan bahwa terdapat *efficiency gap* yang substansial antara optimalitas teoritis dan optimalitas aktual yang dapat dicapai di bawah batasan regulatif.

Dalam kerangka yang lebih luas, integrasi ESG menjadi kebutuhan utama dalam pengelolaan portofolio jangka panjang. Meta-analisis oleh Friede, Busch, dan Bassen (2015) menunjukkan bahwa kinerja ESG secara umum berkorelasi positif dengan kinerja keuangan. Selain itu, penelitian Arouri et al. (2025) menyoroti pentingnya keterhubungan aset hijau dengan emas sebagai aset lindung nilai, sehingga memberikan pandangan baru mengenai dinamika portofolio yang berorientasi pada keberlanjutan dan stabilitas jangka panjang.

KESIMPULAN

Secara keseluruhan, penelitian ini memberikan kontribusi teoretis dan praktis dengan memperlihatkan evolusi teori portofolio, mengidentifikasi kekuatan dan kelemahan masing-masing pendekatan, serta mengusulkan arah pengembangan penelitian di masa depan. Dengan menggabungkan teori, data, teknologi, dan regulasi, optimalisasi portofolio modern dapat dikembangkan ke arah yang lebih adaptif, berkelanjutan, dan sesuai dengan kebutuhan nyata investor institusional.

Dengan demikian, penelitian berikutnya dapat direkomendasikan bahwa Pertama, perlunya pengembangan model optimasi portofolio yang memasukkan *institutional constraints* secara eksplisit dalam kerangka ML dan DRL. Kedua, penelitian mengenai *explainable AI* dalam konteks portofolio sangat diperlukan untuk menjembatani kebutuhan regulasi dan transparansi. Ketiga, pengembangan model integratif berbasis ALM–ML–DRL–ESG akan menjadi arah baru dalam literatur optimalisasi portofolio jangka panjang. Keempat, studi empiris yang menguji model integratif tersebut pada data pasar nyata, terutama pada investor institusional di negara berkembang, masih sangat terbuka. Kelima, pendekatan *robust optimization* dan *stress-testing* yang dikombinasikan dengan metode kecerdasan buatan dapat menjadi solusi terhadap

ketidakpastian pasar yang meningkat.

DAFTAR PUSTAKA

- Abate, G., Bonafini, M., and Ferrari, P. (2022). Portfolio constraints: An empirical analysis of diversification, shrinkage and out of sample stability. *European Journal of Operational Research*.
- Allen, F. and Faulhaber, G. (1989). Signaling by underpricing in the IPO market. *Journal of Financial Economics*.
- Alda, M. (2025). Importance of Portfolio Optimization in SRI and conventional pension funds. SpringerOpen.
- Amini, A., Cont, R., & Noh, J. (2022). Deep learning for portfolio optimization. *Neural Computation*.
- Arouri, M., Lahiani, A., and Nguyen, D.K. (2025). Dynamic connectedness and hedging effectiveness between green bonds, ESG indices, and gold. *European Financial Management*. <https://doi.org/10.1111/eufm.12456>
- Avellone, A., and Foroni, C. (2025). Bank portfolio allocation under Basel IV: Capital charges, expected shortfall and regulatory trade offs. *Finance Research Letters*. <https://doi.org/10.1016/j.frl.2024.104350>
- Bae, K., Stulz, R.M., and Tan, H. (2008). Do local analysts know more? A cross country comparative study. *Journal of Financial Economics*.
- Bekaert, G., Harvey, C. R., and Lundblad, C. (2007). Liquidity and expected return: Lessons from emerging markets. *Review of Financial Studies*.
- Bennett, P., Kim, D., and Li, J. (2023). Regulatory capital, portfolio rebalancing and bank risk taking under stress. *Journal of Banking and Finance* <https://doi.org/10.1016/j.jbankfin.2023.106904>
- Bian, W., Deng, S., and Liu, Y. (2024). Dynamic connectedness and hedging in ESG and commodity markets. *Emerging Markets Finance and Trade*.
- Bikker, J. A., and Broeders, D. (2010). Pension funds asset allocation and risk management: Does size matter? *Journal of Banking and Finance* <https://doi.org/10.1016/j.jbankfin.2009.08.017>
- Broda, S. A., De Nard, G., and Walker, P. (2025). Dynamic asset allocation with reinforcement learning. *Institute of Financial Services University of Zurich*.

- Campbell, J. Y., and Viceira, L. M. (2002). *Strategic asset allocation: Portfolio choice for long term investors*. Oxford University Press.
- Davis, E. P., and Steil, B. (2001). *Institutional investors and corporate governance*. MIT Press.
- Fischer, T., and Krauss, C. (2018). Deep learning with long short term memory networks for financial market predictions. *European Journal of Operational Research*.
- Friede, G., Busch, T., and Bassen, A. (2015). ESG and financial performance: Aggregated evidence from more than 2000 empirical studies. *Journal of sustainable finance and investment*.
- He., J., Hua, C., Zhou, C., and Zheng, Z. (2023). Reinforcement learning portfolio with dynamic embedding of market information. *Journal of Financial Data Science*.
- Jang, S., Clare, A., and Owadally, I. (2024). Stochastic asset liability management for pension funds: Balancing volatility and longevity risk. *Journal of Pension Economics and Finance*.
<https://doi.org/10.1017/S1474747224000114>
- Jeon, J. H., Lee, Z., and Park, D. (2025). Reinforcement learning based dynamic asset allocation with technical and macro economics analysis. *Journal of Economic Development*.
- Liang, Z., Wang, J., Zhang, X., Sun, H., Chan, W., and Li, Y. (2020). Enhancing investment portfolio management with machine learning techniques. DOI: 10.13140/RG.2.2.31000.30720
- Lintner, J. (1965). The valuation of risk assets and the selection of risky investments in stock portfolios and capital budgets. *Review of Economics and Statistics*.
- Markowitz, H. (1952). Portfolio selection. *The Journal of Finance*.
<https://doi.org/10.2307/2975974>
- Mossin, J. (1966). Equilibrium in a capital asset market. *Econometrica*, 34(4), 768–783.
- Priharsari, D. (2022). Systematic Literature Review di Bidang Sistem Informasi dan Ilmu Komputer. *Jurnal Teknologi Informasi dan Ilmu Komputer*.
- Rockafellar, R. T., and Uryasev, S. (2000). Optimization of conditional value at risk. *Journal of risk*.
- Ross, S. A. (1976). The Arbitrage theory of capital asset pricing. *Journal of Economic Theory*.
- Sharpe, W. F. (1964). Capital asset prices: A theory of market equilibrium under conditions of risk. *The Journal of Finance*.
- Sharpe, W. F. (1966). Mutual fund performance. *The Journal of Business*.

Weiye Wu and Hargreaves, C (2023). Deep reinforcement learning approach to portfolio optimization in the Australian stock market. *Computer Science and Robotics Technology*.
<https://doi.org/10.5772/acrt.20230095>.

Watajdid, N. I., Lathifah, A., Andini, D. S., and Fitroh (2021). Systematic Literature Review: Peran Media Sosial terhadap Perkembangan Digital Marketing. *Jurnal Sains Pemasaran Indonesia*.

Zhang, Z., Zohren, S., and Roberts, S. (2020). Deep learning for portfolio optimization, *Quantitative Finance*