

BAB II

TINJAUAN PUSTAKA

2.1 Landasan Teori

2.1.1 Tsunami

Tsunami adalah serangkaian gelombang laut besar yang disebabkan oleh gangguan di dasar laut, seperti gempa bumi, letusan gunung berapi, atau tanah longsor bawah laut (Intan et al., 2024). Gelombang ini bisa juga dipicu oleh dampak meteor besar di laut, gempa dan longsor (Pramana, 2015). Saat gangguan terjadi, energi besar dilepaskan dan disebarkan ke seluruh kolom air, menyebabkan gelombang tinggi yang bisa bergerak dengan kecepatan sangat tinggi hingga ratusan kilometer per jam (Sholeh, 2022). Ketika mendekati pantai, gelombang ini melambat namun bertambah tinggi, menyebabkan kerusakan besar dan banjir di area pesisir. Secara teknis, tsunami terbentuk ketika pergeseran besar di dasar laut memindahkan sejumlah besar air dalam waktu singkat (Yulaelawati, 2008). Pergerakan ini bisa diakibatkan oleh sesar geologi yang tiba-tiba bergerak, aktivitas vulkanik yang meletus, atau tanah longsor yang runtuh ke dalam laut (Intan et al., 2024).

Fenomena tsunami yang terjadi akibat longsor memiliki beberapa jenis, yaitu longsor dari atas air (*sub-aerial*), longsor dari bawah air (*submarine*), dan campuran keduanya (*partially submerged*) (Løvholt et al., 2015; Pilvar et al., 2019; Takabatake et al., 2020). Setelah terbentuk, gelombang tsunami menyebar ke segala arah dari titik gangguan dengan panjang gelombang yang bisa mencapai ratusan kilometer (Nasir et al., 2015). Berbeda dengan gelombang biasa yang disebabkan oleh angin, panjang gelombang tsunami sangat panjang dan energinya terdistribusi dari permukaan hingga dasar laut, sehingga bisa menempuh jarak yang sangat jauh tanpa kehilangan banyak energi (Nosov et al., 2021). Sebagai contoh, tsunami yang terjadi di Samudra Hindia pada tahun 2004 adalah salah satu

yang paling merusak dalam sejarah (Alviani, 2021). Tsunami ini dipicu oleh gempa bumi berkekuatan 9,1-9,3 skala Richter yang terjadi di lepas pantai barat Sumatra, Indonesia. Gelombang yang dihasilkan mencapai tinggi hingga 30 meter di beberapa tempat dan menyebabkan kerusakan besar di 14 negara, termasuk Indonesia, Thailand, Sri Lanka, dan India. Lebih dari 230.000 orang tewas dan jutaan lainnya kehilangan tempat tinggal. Contoh ini menunjukkan betapa dahsyatnya kekuatan alam ini dan pentingnya sistem peringatan dini serta pendidikan masyarakat untuk mengurangi dampak bencana tsunami (Rahardian, 2023).

2.1.3 Akurasi simulasi

Akurasi simulasi dalam konteks simulasi berbasis komputer seperti *Computational Fluid Dynamics* (CFD) merujuk pada sejauh mana hasil simulasi mendekati solusi sebenarnya dari masalah yang dimodelkan. Akurasi ini sangat penting karena menentukan keandalan dan validitas hasil simulasi yang digunakan untuk pengambilan keputusan dalam desain, analisis, dan penelitian ilmiah (Rohayani et al., 2023). Secara teknis, akurasi simulasi dipengaruhi oleh beberapa faktor utama: kualitas dan resolusi mesh, model fisik yang digunakan, metode numerik, dan kondisi batas serta inisial yang diterapkan. Mesh yang lebih halus umumnya memberikan hasil yang lebih akurat karena mampu menangkap detail-detail kecil dalam aliran fluida, namun juga memerlukan lebih banyak waktu komputasi (Naga et al., 2023). Pemilihan model fisik yang tepat, seperti model turbulensi dalam simulasi aliran udara, juga sangat berpengaruh terhadap akurasi hasil (Yunus, 2023). Metode numerik yang digunakan untuk menyelesaikan persamaan diferensial parsial juga harus dipilih dengan hati-hati untuk menghindari kesalahan numerik seperti dispersi dan dissipasi yang akan berpengaruh besar pada akurasi simulasi. Akurasi dari simulasi diukur menggunakan *Root Mean Squared Error* (RMSE) dari perbandingan data eksperimen sesungguhnya dan hasil simulasi sesuai fungsi **2.13** dengan $\hat{y}$ adalah data simulasi dan y adalah data observasi dan

n adalah jumlah data.

$$RMSE = \sqrt{\frac{(\hat{y} - y)^2}{n}} \quad (2.1)$$

2.1.4 **Computational Fluid Dynamic (CFD)**

Computational Fluid Dynamics (CFD) adalah bidang ilmu yang menggunakan metode numerik dan algoritma komputer untuk menganalisis dan menyelesaikan masalah yang melibatkan aliran fluida (Stephanus Timur Lintang Samudra, 2023). CFD memungkinkan simulasi dan prediksi perilaku fluida dalam berbagai kondisi, termasuk aerodinamika, hidrodinamika, perpindahan panas, dan aliran reaktif dalam mesin pembakaran (Tu, 2023). Insinyur dan ilmuwan dapat memvisualisasikan dan mempelajari karakteristik aliran fluida yang kompleks tanpa perlu melakukan eksperimen fisik langsung yang mahal dan memakan waktu dengan menggunakan CFD. Simulasi CFD melibatkan beberapa langkah penting, pertama domain fisik yang akan disimulasikan dibagi menjadi jaringan sel kecil atau mesh, kemudian persamaan dasar yang mengatur aliran fluida seperti persamaan *Incompressible Navier-Stokes* diterapkan pada setiap sel dalam mesh. Dan karena solusi dari persamaan *Incompressible Navier-Stokes* tersebut rumit diselesaikan secara analitik, metode numerik digunakan untuk penyelesaiannya.

Metode numerik seperti metode volume hingga, metode elemen hingga, atau metode perbedaan hingga digunakan untuk menyelesaikan persamaan ini secara iteratif dengan mendiskritisasi persamaan Navier-Stokes ini. Setelah didiskritisasi persamaan akan menjadi berbentuk linear dan solusi nya akan dapat lebih mudah ditemukan setelah persamaannya sudah dalam bentuk linear. Selanjutnya, solusi hasil diskritisasi sementara pada iterasi sebelumnya akan digunakan untuk memperbaharui solusi selanjutnya hingga solusi konvergen dan menghasilkan distribusi aliran fluida yang stabil dan akurat (Sharma, 2021). Sebagai contoh, CFD

digunakan dalam simulasi dan analisis dampak tsunami yang disebabkan oleh longsor bawah laut maupun diatas laut. Simulasi CFD dapat membantu memahami bagaimana gelombang tsunami terbentuk dan bergerak setelah longsor terjadi secara lebih mendetail mulai dari bentuk longsor hingga bentuk gelombang yang tercipta. Pergerakan air divisualisasikan untuk dievaluasi lewat mesh per mesh, lebih jauh lagi peneliti dapat mengidentifikasi area dengan potensi dampak tinggi dan memprediksi waktu tiba serta ketinggian gelombang (Yavari-Ramshe & Ataie-Ashtiani, 2016). Hal ini sangat penting untuk peringatan dini dan mitigasi bencana tsunami dalam pengembangannya.

2.1.6 Finite Volume Method (FVM)

Metode Volume Hingga (*Finite Volume Method*, FVM) adalah salah satu teknik numerik yang digunakan untuk mendiskritisasi persamaan diferensial parsial rumit agar dapat disederhanakan menjadi persamaan linear (Nasir et al., 2015). Secara teknis, FVM melibatkan beberapa langkah kunci. Pertama, domain fisik dibagi menjadi jaringan sel atau mesh, di mana setiap sel mewakili volume kontrol. Lalu, persamaan diferensial parsial yang mengatur fenomena fisik diintegrasikan pada setiap volume kontrol untuk menghasilkan persamaan aljabar diskret. Fluks fisik melalui batas-batas setiap volume kontrol dihitung dan digunakan untuk memperbarui nilai-nilai variabel yang sedang disimulasikan (Ali et al., 2023). Setelah itu, langkah diiterasikan ulang sehingga hasil didapatkan konvergen. Metode ini sangat bermanfaat untuk menyederhanakan fungsi persamaan differensial parsial yang rumit. Berikut ditampilkan ilustrasi cara kerja FVM pada **Gambar 2.1**

The diagram illustrates the Finite Volume Method (FVM) workflow. It shows the derivation of the discrete equations for velocity (u_f) and pressure (p_s) using the divergence theorem and face interpolation. The diagram includes a 3D cube representing a control volume, with faces labeled f and s . The velocity vector u is shown at the center of the cube. The pressure vector p is shown at the center of the cube. The diagram also includes a table of face interpolation schemes and a table of temporal discretization schemes.

Divergence Theorem

$$\int_V \nabla \cdot \mathbf{F} dV = \int_S \mathbf{F} \cdot \mathbf{n} dS$$

Face interpolation scheme:

- 1.) Upwind
- 2.) Second order / linear Upwind
- 3.) Central Differencing
- 4.) QUICK
- 5.) TVD
- 6.) etc.

Temporal discretization scheme:

- 1.) Euler
- 2.) Crank-Nicholson
- 3.) Hybrid

Gambar 2.1 Ilustrasi cara kerja *Finite Volume Method*

Sumber: diolah oleh peneliti

2.1.7 Adaptive Mesh Refinement (AMR)

Adaptive Mesh Refinement (AMR) adalah teknik yang digunakan dalam simulasi numerik untuk meningkatkan efisiensi dan akurasi dengan secara dinamis menyempurnakan (*refinement*) atau mengurangi (*coarsening*) resolusi mesh berdasarkan kebutuhan lokal selama simulasi. Perangkat lunak open-source OpenFOAM untuk simulasi Computational Fluid Dynamics (CFD) digunakan dan AMR memungkinkan mesh untuk secara otomatis beradaptasi dengan perubahan karakteristik aliran, seperti gradien kecepatan, tekanan, atau variabel lain yang relevan, sehingga sumber daya komputasi dapat difokuskan pada area yang memerlukan resolusi tinggi (Sadrehaghighi, 2023) pada simulasi OpenFOAM tersebut. AMR di OpenFOAM bekerja dengan cara memberikan kriteria-kriteria tertentu selama iterasi simulasi dan menilai di mana perlu dilakukan *refinement* atau *coarsening* sesuai dengan parameter tersebut. Perangkat OpenFOAM digunakan untuk mensimulasikan gelombang detonasi dalam tabung persegi (McGough, 2020). Selain disimulasikan, berbagai solver juga diuji, berbagai metode penyalaan detonasi digunakan, dan sensitivitas yang berbeda pada parameter AMR di solversnya juga diujikan.


AMR digunakan untuk memperhalus mesh di area dengan gradien kecepatan dan tekanan tinggi, sementara di area dengan aliran lebih

seragam dan gradien rendah, AMR memperbesar sel mesh untuk mengurangi jumlah sel total dan menghemat waktu komputasi. Parameter pemeshing adaptif dieksplorasi, dan ditemukan bahwa tidak lebih dari 4 lapisan buffer meningkatkan akurasi solusi secara signifikan, sedangkan batas bawah gradien tekanan yang dinormalisasi lebih kecil dari 0,05 meningkatkan biaya komputasi. Hasil dari penelitian tersebut menunjukkan AMR dapat mengurangi biaya komputasi hingga 85% dan lebih dari 96%. Pengembangan AMR pada simulasi tsunami longsor yang sebelumnya dilakukan (Alphalevy, 2024) dilakukan dengan menerapkan optimasi SAO agar dapat mengurangi biaya komputasi.

2.1.8 Surrogate Based Sequential Approximation Optimization

SAO adalah pendekatan yang digunakan untuk mengatasi permasalahan optimasi yang mahal secara komputasional dengan menggunakan model pengganti yang lebih sederhana dan cepat dievaluasi. Konsep ini pertama kali diperkenalkan pada tahun 1960-an dalam konteks optimasi rekayasa, terutama di bidang aerodinamika dan rekayasa struktural. Penggunaan model kriging sebagai model pengganti menjadi populer dalam design of experiments (DoE) dan simulasi komputer, menawarkan pendekatan yang fleksibel untuk membangun model yang dapat menangkap non-linearitas kompleks mulai era 1980-an dan 1990-an. Metode optimasi sekuensial seperti metode Powell, algoritma genetik, dan simulated annealing juga mulai digunakan bersama dengan surrogate models untuk meningkatkan efisiensi pencarian solusi optima (Blank, 2022). Konsep Efficient Global Optimization (EGO) diperkenalkan dengan menggabungkan kriging dengan optimasi sekuensial untuk menemukan solusi optimal global secara efisien pada tahun 2000-an. Surrogate model seperti Support Vector Machines (SVM), Neural Networks, dan Radial Basis Functions (RBF) mulai diterapkan dalam berbagai bidang, termasuk rekayasa, keuangan, dan biologi. Perkembangan metode Bayesian Optimization pada dekade 2010-an memperluas aplikasi *surrogate-based*

optimization, terutama dalam pengoptimalan hiperparameter untuk model machine learning dan deep learning. Kombinasi dengan metode multi-objective optimization (seperti MOBO) dan penggunaan dalam high-dimensional optimization problems semakin memperluas cakupan aplikasi dan meningkatkan efektivitas metode SAO. Surrogate Based Sequential Approximation Optimization (SAO) adalah metode yang digunakan untuk mengoptimalkan fungsi yang mahal untuk dievaluasi, seperti dalam desain teknik, simulasi numerik kompleks, atau eksperimen fisik yang memerlukan biaya dan waktu besar (Xu et al., 2023). Fungsi mahal adalah fungsi yang untuk mendapatkan nilai evaluasinya diperlukan waktu yang lama atau usaha yang sulit (Alizadeh et al., 2020). Metode ini menggunakan model pengganti (*surrogate model*) yang lebih murah untuk dievaluasi dan secara bertahap memperbaruinya berdasarkan hasil evaluasi aktual dari fungsi mahal tersebut. Tujuannya adalah untuk menemukan solusi optimal dengan meminimalkan jumlah evaluasi langsung terhadap fungsi mahal (Bliek, 2022). Secara umum kerja surrogate model sesuai dengan jurnal (Eriksson et al., 2019) ditampilkan pada **Bagan 2.1** sebagai berikut:




Bagan 2.1 Flowchart Surrogate Model

Sumber: diolah oleh peneliti

SAO terdiri dari beberapa langkah umum dalam penerapannya. Pertama, sejumlah titik *sample* awal dievaluasi pada fungsi mahal untuk membangun surrogate model awal. Model pengganti ini bisa berupa *Gaussian Process* (GP), *Kriging*, *Radial Basis Function* (RBF), atau metode regresi lainnya yang mampu menangkap perilaku fungsi asli. Optimasi yang dilakukan pada surrogate model untuk menemukan titik baru yang diprediksi menjadi solusi optimal atau memberikan informasi tambahan yang berharga. Pemilihan titik baru dilakukan dengan algoritma yang telah dijelaskan pada

jurnal (Eriksson et al., 2019) ditampilkan pada **Bagan 2.2** sebagai berikut:



Bagan 2.2 Flowchart Pemilihan titik baru

Sumber: diolah oleh peneliti

Titik baru ini kemudian dievaluasi pada simulasi dan digunakan untuk memperbaiki surrogate model. Proses ini diulang secara iteratif hingga konvergensi tercapai atau kriteria penghentian lainnya dipenuhi (Eriksson et al., 2019). Nilai $V_d(x)$ konstan karena desain eskperimennya telah di ordinal kan, maka yang dipertimbangkan hanya $V_s(x)$ saja. Dan karena $V_s(x)$ hanya tergantung pada nilai $s(x)$ fungsi pemilihan titik baru pada langkah 4 dapat disederhanakan menjadi $\argmin_x f(x) = \argmin_x s(x)$. SAO sudah digunakan oleh (Jin et al., 2018) untuk mengoptimalkan desain permukaan aerodinamis sayap pesawat. (Jin et al., 2018) menggunakan optimisasi Berbasis Surrogate (SAO) dalam jurnal-nya dapat membangun model surrogate berdasarkan beberapa simulasi CFD awal. Model ini kemudian digunakan untuk memprediksi desain sayap pesawat tanpa perlu melakukan simulasi CFD penuh untuk iterasi yang banyak. Hanya desain

yang diprediksi optimal oleh model surrogate akan dievaluasi kembali dengan simulasi CFD untuk memvalidasi model yang telah dibuat sehingga secara signifikan mengurangi jumlah simulasi yang diperlukan. SAO diterapkan dalam kerangka komputasi berkinerja tinggi (HPC) menggunakan OpenFOAM.

Pendekatan ini sangat efektif untuk masalah aliran kavitasi dengan menggunakan solver `interPhaseChangeFoam` di OpenFOAM, yang memungkinkan Optimasi parameter secara efisien dengan dukungan HPC dan basis data yang kuat (Jin et al., 2018). SAO menyediakan pendekatan praktis dan efisien untuk mengatasi tantangan optimasi pada fungsi yang mahal, memungkinkan eksplorasi desain yang lebih luas dan solusi optimal yang lebih baik dalam berbagai bidang aplikasi dengan memanfaatkan surrogate models yang lebih cepat dihitung. Penerapan SAO pada konteks optimasi desain permukaan tersebut akan diadopsi pada konteks yang berbeda yaitu parameter AMR untuk simulasi tsunami karena longsor di atas air. Yang mana ini sesuai karena simulasi tsunami karena longsor di atas air juga menggunakan CFD OpenFOAM dan juga harga evaluasi hasilnya cukup menghabiskan waktu komputasi yang lama.

2.1.9 Radial Basis Function (RBF)

Radial Basis Function (RBF) adalah fungsi matematika yang didefinisikan sebagai fungsi dari jarak radial dari suatu titik pusat yang digunakan sebagai salah satu. RBF pertama kali diperkenalkan oleh Rolland Hardy pada tahun 1971 dalam konteks interpolasi geostatistik, di mana RBF digunakan untuk memecahkan masalah interpolasi data geofisika. RBF menjadi populer dalam bidang interpolasi karena sifatnya yang bagus dalam meminimalisir kesalahan interpolasi pada dataset yang sparse dan tidak terstruktur, dengan fungsi-fungsi umum seperti *Gaussian*, *Multiquadric*, dan *Inverse Multiquadric* RBF mulai banyak digunakan pada tahun 1980-an. Aplikasi RBF berkembang ke bidang rekayasa dan ilmiah lainnya, termasuk analisis citra, pengenalan pola, dan pemrosesan sinyal

pada era 1990-an dan 2000-an. Penggunaan RBF dalam konteks *machine learning* dan *neural networks* juga mulai dieksplorasi, terutama dalam *Radial Basis Function Networks* (RBFNs). Interpolasi RBF adalah salah satu pendekatan yang paling populer untuk memperkirakan data tersebar dalam jumlah dimensi yang umum (berapa saja). RBF sering digunakan dalam berbagai aplikasi, termasuk interpolasi data, aproksimasi fungsi, dan pemodelan regresi (Eriksson et al., 2019). Secara umum, RBF memiliki bentuk pada **Persamaan 2.2**

$$\varphi(x) = \varphi(\|x - x_i\|) \quad (2.2)$$

dimana φ adalah fungsi yang bergantung pada jarak kartesian x atau norma $\|x - x_i\|$ dari suatu titik x ke titik lainnya, beberapa bentuk umum RBF yang digunakan termasuk *Gaussian*, *Multiquadratic* dan *Inverse Multi Quadratic*, dimana masing-masing memiliki bentuk yang sedikit berbeda untuk φ . RBF sering digunakan untuk mengestimasi nilai fungsi di titik-titik yang tidak terdapat dalam data pada fungsi yang mahal untuk mengaproksimasi titik optimal. RBF menghitung bobot masing-masing titik data berdasarkan jaraknya dari titik yang akan diestimasi kemudian menggunakan bobot tersebut untuk menghitung nilai perkiraan fungsi. Secara matematik RBF ditulis sebagai pada **Persamaan 2.3** berikut:

$$f(x) = \sum_{i=1}^N \lambda_i \varphi(\|x - x_i\|) + p(x, c_j) \quad (2.3)$$

dimana $f(x)$ adalah fungsi yang akan diestimasi, x_i adalah titik-titik data yang diketahui, λ_i adalah bobot yang akan ditentukan, $\varphi(\cdot)$ adalah fungsi kernel cubic (r^3) dan $p(x, c_j)$ adalah fungsi ekor polinomial yang menjamin kestabilan solusi dari surrogate model (Eriksson et al., 2019; Gutmann, 2001). Menentukan bobot λ_i dan c_j perlu memecahkan sistem persamaan linear yang berasal dari **Persamaan 2.4** fungsi RBF berikut:

$$\begin{bmatrix} \Phi & P \\ P^T & 0 \end{bmatrix} \begin{bmatrix} \lambda \\ c \end{bmatrix} = \begin{bmatrix} f(x) \\ 0 \end{bmatrix} \quad (2.4)$$

Di mana $\Phi_{ij} = \varphi(\|x_i - x_j\|)$ adalah nilai kernel yang bergantung pada jarak antar titik data x_i dan x_j , dan P_{ij} adalah basis dari fungsi ekor polinomial derajat 1 yang menjamin keberadaan solusi optimum. x_i dan x_j pada penelitian ini diambil dari data input yang berada matriks P_{ij} . RBF dapat melakukan aproksimasi dan interpolasi yang halus dan fleksibel, meskipun dapat terjadi overfitting jika jumlah titik data terlalu besar atau jika parameter RBF dipilih dengan tidak tepat. Oleh karena itu, pemilihan RBF dan parameter yang sesuai sangat penting dalam penggunaan praktisnya.

2.1.10 Hypervolume

Ukuran *hypervolume* digunakan sebagai penghenti algoritma optimasi. *Hypervolume* adalah metrik yang digunakan untuk mengukur kualitas solusi dalam masalah optimasi multi-objektif, terutama dalam konteks Pareto front. Pareto front adalah kumpulan solusi optimal di mana tidak ada solusi lain yang lebih baik dalam semua tujuan objektif (Suzuki et al., 2020). *Hypervolume* mengukur volume ruang objektif yang didominasi oleh set solusi Pareto front dibandingkan dengan suatu titik acuan yang dipilih di luar ruang solusi. Semakin besar *hypervolume*, semakin baik solusi Pareto front karena menunjukkan bahwa solusi tersebut mencakup ruang yang lebih besar dalam tujuan objektif.

Hypervolume membantu dalam mengevaluasi dan membandingkan kualitas berbagai Pareto front yang dihasilkan oleh algoritma optimisasi, serta berfungsi sebagai indikator kinerja untuk mengidentifikasi apakah suatu algoritma mampu menghasilkan solusi yang baik dan beragam. Proses perhitungan *hypervolume* melibatkan penentuan titik acuan, menghitung volume dominasi dari setiap solusi hingga titik acuan, dan menjumlahkan volume tersebut untuk mendapatkan *hypervolume* total. *Hypervolume* menyediakan cara efektif untuk mengukur dan memvisualisasikan performa solusi dalam optimisasi multi-objektif (Lin et al., 2022).

2.2 Hasil Penelitian Terdahulu

Beberapa penelitian sebelumnya tentang simulasi gelombang tsunami oleh longsoran yang menjadi acuan dalam skripsi ini disajikan dalam **Tabel 2.1**.

Tabel 2.1 Hasil Penelitian Terdahulu

No.	Title	Hasil	Model	Gap
1.	Landslide-generated wave simulation using coupled multi-phase flow and Boussinesq-type models (Latifah et al., 2024).	Penelitian ini membahas tentang studi numerik gelombang tsunami yang dihasilkan oleh longsoran yang menggunakan model CFD multi-fase untuk fenomena longsoran dan model gelombang permukaan berdasarkan persamaan tipe <i>Boussinesq</i> untuk propagasi gelombang.	CFD multi-fase dan persamaan <i>Boussinesq</i>	Pengembangan model simulasi untuk mengurangi waktu komputasi
2.	Tsunami generated by a granular collapse down a rough inclined plane (Viroulet et al., 2014)	Peneliti mengilustrasikan dinamika kompleks runtuhnya media <i>granular</i> kering ke dalam air untuk memprediksi amplitudo tsunami dari longsoran tebing. Mereka	CFD multi-fase dan granular flow model	Pengembangan model simulasi untuk meningkatkan akurasi bentuk landslide

No.	Title	Hasil	Model	Gap
		menemukan perbedaan penting antara runtuhnya granular kering dan basah, serta pengaruh massa dan kemiringan.		
3.	Physical Modeling of Tsunamis Generated by Subaerial, Partially Submerged, and Submarine Landslide (Takabatake et al., 2020)	Penelitian ini dilakukan tiga jenis eksperimen tsunami yang disebabkan oleh longsor (<i>subaerial</i> , <i>partially submerged</i> , dan <i>submerged</i>) dan diselidiki dengan berbeda parameter.	CFD multi-fase dan complex rheology	Pengembangan model simulasi untuk meningkatkan akurasi bentuk <i>Wave time series</i> dan pembuatan eksperimen
4.	Effect of Grain Size on Subaerial Granular Landslide and Resulting Impulse Waves: Experiment and Multi-Phase Flow Simulation (Lee & Huang, 2022)	penelitian ini investigasi eksperimental dan numerik dilakukan untuk mengeksplorasi pengaruh ukuran butir terhadap gelombang tsunami yang dihasilkan oleh longsor <i>subaerial</i> .	CFD multi-fase dan granular flow model	Pengembangan model simulasi untuk menganalisis pengaruh parameter fisik pada model

No.	Title	Hasil	Model	Gap
5.	Granular Porous Landslide Tsunami Modelling – the 2014 Lake Askja Flank Collapse (Rauter et al., 2022)	Penelitian ini Menunjukkan kemajuan yang signifikan dalam pemodelan tsunami dari longsor <i>subaerial</i> . Dengan menganalisis eksperimen skala kecil secara retroaktif, simulasi ini telah mencapai tingkat presisi yang luar biasa dalam mereplikasi karakteristik gelombang dan perilaku puing-puing tanah longsor.	CFD multi-fase dan granular flow model	Penerapan Model pad kasus besar
6.	pySOT and POAP: Anevent-driven asynchronous framework for surrogate optimization (Eriksson et al., 2019)	Penelitian ini membahas tentang <i>Plumbing for Optimization with Asynchronous Parallelism</i> (POAP) dan <i>Python Surrogate Optimization Toolbox</i> (pySOT), yang merupakan kerangka kerja untuk optimisasi global fungsi-fungsi mahal	Surrogate Model	Pembuatan library di python untuk pemodelan surrogate model

No.	Title	Hasil	Model	Gap
		dengan evaluasi konkuren.		
7.	A Parameter Optimization Framework Based on OpenFOAM with HPC and Database Support (Jin et al., 2018)	Penelitian ini membahas tentang kerangka kerja optimasi parameter solver OpenFOAM yang dihadapi dalam simulasi CFD untuk kasus kavitasi menggunakan pendekatan surrogate based model.	Surrogate Based Sequential Approximation Optimization Model	Penerapan SAO pada kasus sesungguhnya
8.	Detonation Modeling in OpenFOAM Using Adaptive Mesh Refinement (McGough, 2020)	Penelitian ini parameter AMR dieksplorasi dan ditemukan bahwa penggunaan AMR kasus model ledakan dapat memangkas biaya komputasi hingga 85% dengan hasil akurasi yang hampir sama dengan mesh statis.	Model Analisis Sensitivitas	Optimasi Parameter dengan analisis sensitivitas konvensional
9.	Improved Sequential Approximate Optimization for	Penelitian ini mengusulkan pendekatan pengembangan	Surrogate Based Sequential	Pengembangan SAO dalam penerapan objektif koefisien

No.	Title	Hasil	Model	Gap
	Aerodynamic Design Benchmark Problem (Wang et al., 2019)	SAO untuk optimisasi desain aerodinamika terutama pada kasus minimasi koefisien <i>drag</i> RAE-2822 dalam aliran transonik <i>viscous</i> .	Approximation Optimization Model	drag dan parameter yang berbeda
10.	A Radial Basis Function Method for Global Optimization (Gutmann, 2001)	Penelitian ini memperkenalkan <i>radial basis function</i> untuk mencari nilai minimum global dari fungsi nonkonveks kontinu dengan asumsi bahwa evaluasi fungsi mahal dan tidak ada informasi tambahan yang tersedia.	Surrogate Model	Penerapan Radial Basis function pada surrogate model
11.	Multicriteria Optimal Latin Hypercube Design-Based Surrogate-Assisted Design Optimization for a Permanent-Magnet Vernier Machine (Ma et al., 2022)	Penelitian ini mengusulkan metode optimisasi desain yang efisien berbantu surrogat berdasarkan desain <i>Latin hypercube</i> (LHD) <i>optimal multicriteria</i> untuk optimisasi multi-objektif mesin vernier bermagnet permanen	Surrogate model	Penerapan sampling Optimal Latin Hypercube Design

No.	Title	Hasil	Model	Gap
		berpemasangan permukaan (SPMVM).		
12.	Multi-objective Bayesian Optimization using Pareto-frontier Entropy (Suzuki et al., 2020)	Peneliti mengusulkan pencarian entropi <i>Pareto-frontier</i> (PFES) untuk optimasi Bayesian multi-tujuan (MBO).	Multi-objective Bayesian Optimization	Penerapan Konsep Pareto-Front untuk Masalah Multi-objective problem

Sumber: diolah oleh peneliti

Berbagai studi sebelumnya telah menunjukkan kemajuan penting dalam simulasi gelombang tsunami yang dihasilkan oleh longsor, baik dari sisi metode numerik maupun eksperimen validasi. Latifah et al. (2024) menggabungkan model CFD multi-fase untuk fenomena longsor dan model Boussinesq untuk propagasi gelombang, dengan fokus pada pengembangan model untuk mengurangi waktu komputasi. Viroulet et al. (2014) dan Lee & Huang (2022) mengeksplorasi dinamika granular flow, dengan menginvestigasi pengaruh kondisi longsor, seperti kemiringan dan ukuran butir, terhadap amplitudo dan karakteristik gelombang tsunami. Di sisi lain, penelitian Takabatake et al. (2020) memperkaya basis data eksperimen tsunami dari berbagai jenis longsor (subaerial, partially submerged, dan submerged), menyediakan data penting untuk validasi simulasi numerik. Beberapa penelitian seperti Rauter et al. (2022) berhasil membawa simulasi ke tingkat presisi yang tinggi dengan mereplikasi karakteristik gelombang dan perilaku puing longsor pada skala nyata. Meskipun demikian, sebagian besar penelitian tersebut masih menghadapi tantangan dalam aspek efisiensi komputasi, terutama ketika simulasi diperbesar ke skala yang lebih luas. McGough (2020) menunjukkan bahwa penggunaan Adaptive Mesh Refinement (AMR) dapat mengurangi biaya

komputasi hingga 85% pada kasus detonasi, namun optimalisasi parameter AMR masih dilakukan menggunakan analisis sensitivitas konvensional. Dalam ranah optimasi parameter numerik, beberapa framework berbasis surrogate model seperti pySOT dan POAP (Eriksson et al., 2019), serta pendekatan SAO (Jin et al., 2018; Wang et al., 2019) telah diterapkan untuk mempercepat perhitungan pada masalah optimisasi kompleks di bidang lain, seperti aerodinamika dan desain mesin listrik (Ma et al., 2022). Selain itu, pendekatan baru dalam multi-objective optimization seperti Pareto-Frontier Entropy (Suzuki et al., 2020) memperlihatkan potensi besar untuk diterapkan dalam konteks masalah multi-objektif. Meskipun telah banyak studi yang mengembangkan metode simulasi maupun optimasi di bidang masing-masing, hingga saat ini belum ada penelitian yang secara khusus menggabungkan optimalisasi parameter AMR dengan metode SAO untuk simulasi tsunami akibat longsor. Oleh karena itu, gap penelitian ini terletak pada upaya sistematis mengoptimalkan parameter AMR menggunakan *surrogate-based sequential approximation optimization* untuk meningkatkan efisiensi waktu eksekusi simulasi tsunami tanpa mengurangi akurasi hasil. Optimalisasi ini penting untuk memungkinkan ekspansi simulasi ke skala yang lebih besar dengan sumber daya komputasi yang lebih terjangkau.

2.3 Kerangka Pemikiran



Gambar 2.2 Diagram Tulang Ikan Kerangka Pemikiran

Sumber: diolah oleh peneliti

AMR sudah digunakan peneliti sebelumnya untuk mengurangi permasalahan waktu komputasi. AMR juga sudah pernah dianalisis sensitivitasnya dan terbukti dapat meningkatkan komputasi dan akurasi secara signifikan. Analisis sensitivitas dilakukan dengan cara menjalankan serangkaian eksperimen simulasi pada lima parameter AMR (sediment refinement criteria, water refinement criteria, refinement interval, buffer layer dan n-layer) pada desain eksperimen tertentu. Namun begitu, karena proses analisis sensitivitas tersebut tidak praktis dari segi waktu maka perlu adanya pendekatan optimasi lain yang dapat meningkatkan potensi AMR dengan lebih praktis. Optimasi dengan pendekatan model SAO diajukan untuk parameter AMR pada penelitian kali ini. Model SAO adalah *data driven* model yang perlu input data bagi pembentukan model maka pertama-tama simulasi perlu dilakukan untuk pengambilan data awal. Simulasi dilakukan dengan menggunakan aplikasi *OpenFOAM* dan data hasil simulasinya di proses

dengan *Jupyter notebook*.

Data-data yang dihasilkan terlebih dahulu disiapkan terlebih dahulu dengan cara data dibersihkan dan penyusunan data dalam format *Comma Separated Value* (CSV). Selanjutnya data dikomparasi dengan nilai eksperimen yang sesungguhnya. Digitasi data dilakukan untuk membandingkan nilai grafik dari eksperimen sesungguhnya dengan simulasi yang telah dilakukan. Sebanyak 20 data yang telah diambil dan dievaluasi akurasi dengan data eksperimen dengan menggunakan ukuran kuantitatif yaitu *root mean square error* dari grafik dan waktu komputasinya dengan melihat *Execution time* disusun kembali ke dalam tabel untuk selanjutnya dievaluasi bagaimana hasil optimasi yang telah dilakukan dapat meningkatkan waktu komputasi dan akurasi. Terakhir, hasil evaluasinya dibandingkan dengan cara konvensional sebelumnya yaitu analisis sensitivitas untuk dilihat seberapa besar peningkatan waktu komputasi yang didapatkan dan konfigurasi parameter ditentukan untuk selanjutnya dimanfaatkan bagi peneliti lainnya yang menggunakan *tools* AMR pada simulasi CFD-nya.