

**PERSAMAAN GELOMBANG SATU DIMENSI MENGGUNAKAN
METODE *FINITE DIFFERENCE EXPLICIT* DAN *NEURAL NETWORK***

SKRIPSI



Diajukan Oleh

Fardika Armawanto

NPM 20330002

**PROGRAM STUDI PENDIDIKAN FISIKA
FAKULTAS PENDIDIKAN MATEMATIKA ILMU PENGETAHUAN
ALAM DAN TEKNOLOGI INFORMASI
UNIVERSITAS PGRI SEMARANG**

MARET 2024

**PERSAMAAN GELOMBANG SATU DIMENSI MENGGUNAKAN
METODE *FINITE DIFFERENCE EXPLICIT* DAN *NEURAL NETWORK***

SKRIPSI



Diajukan Oleh

Fardika Armawanto

NPM 20330002

**PROGRAM STUDI PENDIDIKAN FISIKA
FAKULTAS PENDIDIKAN MATEMATIKA ILMU PENGETAHUAN
ALAM DAN TEKNOLOGI INFORMASI
UNIVERSITAS PGRI SEMARANG**

MARET 2024

HALAMAN PERSETUJUAN

Skripsi Berjudul

**PERSAMAAN GELOMBANG SATU DIMENSI MENGGUNAKAN METODE
FINITE DIFFERENCE EXPLICIT DAN NEURAL NETWORK**

yang diajukan oleh

Fardika Armawanto

NPM 20330002

telah disetujui untuk dilaksanakan

Semarang,

Pembimbing 1



Wawan Kurniawan, M.Si

NIDN 0629118101

Pembimbing 2



Joko Saefan, S.Si., M.Sc

NIDN 0620078101

HALAMAN PENGESAHAN

PERSAMAAN GELOMBANG SATU DIMENSI MENGGUNAKAN
METODE FINITE DIFFERENCE EXPLICIT DAN NEURAL NETWORK

yang dipersiapkan dan disusun oleh

Fardika Amawanto

20330002

Telah dipertahankan di depan Dewan Penguji pada hari senin, tanggal 1 April
2024 dan dinyatakan telah memenuhi syarat untuk memperoleh gelar Sarjana

Pendidikan

Panitia Ujian

Ketua



Dr. Supandi, S.Si., M.Si.
NIDN 0621067401



Sekretaris




Dr. Affandi Faisal K., S.Si., M.Sc
NIDN 0608108204

Penguji

1. Wawan Kurniawan S.Si., M.Si


NIDN 0629118101



(.....)

2. Joko Saefan, S.Si., M.Sc.


NIDN 0620078101



(.....)

3. Dr. Nur Khoiri, S.Pd., M.T., M.Pd.

NIDN 0611027802



(.....)

HALAMAN PERNYATAAN

Saya yang bertandatangan di bawah ini :

Nama : Fardika Armawanto

NPM : 20330002

Program Studi : Pendidikan Fsika

Menyatakan dengan sesungguhnya bahwa skripsi ini benar-benar merupakan hasil karya sendiri, bukan jiplakan atau karya tulis orang lain, baik Sebagian atau seluruhnya. Pendapat atau temuan orang lain yang terdapat dalam skripsi ini dikutip atau dirujuk berdasarkan kode etik ilmiah.

Semarang, 1 April 2024



Fardika Armawanto

NPM 20330002

**PERSAMAAN GELOMBANG SATU DIMENSI MENGGUNAKAN
METODE *FINITE DIFFERENCE EXPLICIT* DAN *NEURAL NETWORK***

Fardika Armawanto

Program Studi Pendidikan Fisika

Universitas PGRI Semarang Telp (024) 831637

e-mail: fardika178@gmail.com

ABSTRAK

Persamaan gelombang yang berupa persamaan differensial parsial akan diselesaikan secara numerik menggunakan finite diference explicit dan Neural Network. Hasil dari penyelesaian secara numerik menggunakan finite diference explicit akan dilakukan uji stabilitas. Setelah didapatkan kondisi yang stabil maka hal tersebut dinyatakan valid. Sehingga, dari hasil finite diference explicit yang valid dapat di bandingkan dengan metode Neural Network. Sementara itu, keberhasilan Neural Network sangat tergantung pada besarnya epochs yang terjadi pada pemograman dan hasil tersebut dapat dievaluasi dari hasil train loss dan test loss.

Kata kunci: persamaan gelombang, finite diference, Neural Network.

**PERSAMAAN GELOMBANG SATU DIMENSI MENGGUNAKAN
METODE *FINITE DIFFERENCE EXPLICIT* DAN *NEURAL NETWORK***

Fardika Armawanto

Program Studi Pendidikan Fisika

Universitas PGRI Semarang Telp (024) 831637

e-mail: fardika178@gmail.com

ABSTRACT

The wave equation in the form of partial differential equation will be solved numerically using finite difference explicit and Neural Network. The results of the numerical solution using finite difference explicit will be tested for stability. After obtaining a stable condition, it is declared valid. Thus, the valid results of explicit finite difference can be compared with the Neural Network method. Meanwhile, the success of the Neural Network is highly dependent on the number of epochs that occur in the programming and these results can be evaluated from the results of train loss and test loss.

Keywords: wave equation, finite difference, neural network.

KATA PENGANTAR

Assalamualaikum. Wr. Wb.

Segala puji dan syukur Penulis panjatkan kehadirat ALLAH SWT, karena berkat rahmat, hidayah, dan karunia-Nya Penulis dapat menyelesaikan skripsi dengan judul: **“PERSAMAAN GELOMBANG SATU DIMENSI MENGGUNAKAN METODE *FINITE DIFFERENCE EXPLICIT* DAN *NEURAL NETWORK*”**. Shalawat serta salam tak lupa Penulis sampaikan kepada junjungan Nabi Muhammad SAW yang dinantikan syafaatnya di yaumul akhir. Penulisan skripsi ini dilakukan untuk memperoleh gelar Sarjana Pendidikan Fisika di Fakultas Pendidikan Matematika Ilmu pengetahuan Alam dan Teknologi Informasi Universitas PGRI Semarang. Skripsi ini mungkin tidak dapat diselesaikan oleh Penulis tanpa bantuan dan dukungan dari beberapa pihak selama penyusunan skripsi ini oleh karena itu Penulis ingin mengucapkan terimakasih kepada yang terhormat:

1. Dr. Sri Suciati, M.Hum, selaku Rektor Universitas PGRI Semarang;
2. Dr. Supandi, S.Si., M.Si, selaku Dekan Fakultas Pendidikan Matematika Ilmu Pengetahuan Alam dan Teknologi Informasi Universitas PGRI Semarang;
3. Dr. Affandi Faisal Kurniawan, S.Si., M.Sc selaku Ketua Program Studi Pendidikan Fisika Universitas PGRI Semarang;
4. Wawan Kurniawan, S.Si., M.Si., selaku Dosen Pembimbing 1 yang telah memberikan bimbingan, nasihat dan arahan kepada Penulis dalam penyusunan skripsi dengan baik;
5. Joko Saefan, S.Si., M.Sc., selaku Dosen Pembimbing 2 yang telah memberikan bimbingan, nasihat dan arahan kepada Penulis dalam penyusunan skripsi dengan baik;
6. Segenap Dosen Pendidikan Fisika Universitas PGRI Semarang yang telah memberikan ilmu selama Penulis menjadi mahasiswa, semoga ilmu yang diberikan dapat bermanfaat dan menjadi amalan yang tidak akan terputus;
7. Kedua orang tua tercinta Bapak (Siswanto), Ibu (Ismowati) dan seluruh keluarga besar tercinta sebagai tanda bukti hormat dan rasa terima

kasih yang tiada hentinya karena telah memberikan segalanya, semangat, pengorbanan, doa dan limpahan kasih sayangnya kepada Penulis;

8. Kepada kakak dan saudara-saudara yang selalu memberikan semangat dan dukungan penuh dalam keadaan senang maupun susah, serta menerima segala keluh kesah Penulis dalam penulisan skripsi, Penulis ucapkan banyak terimakasih;
9. Teman-teman mahasiswa Program Studi Pendidikan Fisika Angkatan 2020, terutama Hafizh Aji Prakosa dan Diah Ayu Faradita.
10. Teman-teman rumah Penulis yaitu, Muhammad Nurul Iksan, Andhika Fatir Ath-Thariq, Putrama Setyo Wijaya.
11. Semua pihak yang telah membantu Penulis dalam menyelesaikan skripsi ini. Semoga Allah SWT memberikan berkah dan karunia-Nya serta membalas kebaikan mereka;

Akhirnya, Penulis mengucapkan terimakasih dan mohon maaf yang sebesar-besarnya apabila terdapat kata-kata di dalam Penulisan skripsi ini yang kurang berkenan bagi pihak-pihak tertentu. Semoga skripsi ini bermanfaat bagi semua pihak, khususnya bagi Penulis dan umumnya bagi pembaca. Sekian dan Terimakasih.

Semarang, April 2024

Yang menyatakan

Fardika Armawanto
NPM 20330002

MOTTO HIDUP

1. Tidak ada laki-laki yang baik-baik saja di usia muda, semua sedang berjuang dengan ujiannya masing-masing dan tidak ada jalan pintas menuju sukses, maka bertempurlah selayaknya seorang pria. “Fardika Armawanto”
2. Jadikan lah hinaan dan sakit hati sebagai motivasi untuk menjadi lebih baik. “Fardika Armawanto”
3. Allah tidak mengatakan hidup ini mudah. Tetapi allah berjanji, bahwa sesungguhnya Bersama kesulitan ada kemudahan “QS. Al-Insyirah : 5-6”

DAFTAR ISI

HALAMAN JUDUL.....	i
HALAMAN PERSETUJUAN.....	ii
HALAMAN PENGESAHAN.....	iii
HALAMAN PERNYATAAN	iv
ABSTRAK	v
ABSTRACT	vi
KATA PENGANTAR.....	vii
MOTTO HIDUP	ix
DAFTAR ISI	x
DAFTAR GAMBAR	xii
DAFTAR LAMPIRAN	xiii
BAB I PENDAHULUAN	1
A. Latar Belakang.....	1
B. Rumusan Masalah	4
C. Tujuan Penelitian.....	4
D. Manfaat Penelitian	5
E. Sistematika Penulisan.....	5
BAB II LANDASAN TEORI	7
A. Persamaan Gelombang Satu Dimensi	7
B. Metode Finite Difference	9
C. Metode Neural Network.....	11
BAB III METODE PENELITIAN.....	17
BAB IV HASIL PENELITIAN DAN PEMBAHASAN	20

A. Hasil Penelitian	20
1. Penyelesaian metode finite difference explicit.....	20
2. Penyelesaian metode neural network	22
3. Pembahasan.....	27
4. Manfaat Bagi Bidang Pendidikan	29
BAB V KESIMPULAN DAN SARAN.....	31
A. Kesimpulan	31
B. Saran.....	31
DAFTAR PUSTAKA	32
LAMPIRAN.....	37

DAFTAR GAMBAR

Gambar 2. 1 kerangka neural network PINN.....	14
Gambar 4. 1 hasil metode finite difference explicit.....	22
Gambar 4. 2 parameter ν sebesar 1.1	23
Gambar 4. 3 parameter ν sebesar 1.0	24
Gambar 4. 4 parameter ν sebesar 0.5	24
Gambar 4. 5 parameter ν sebesar 0.1	25
Gambar 4. 6 Hasil Neural Network.....	27
Gambar 4. 7 Selisih metode finite diference explicit dan Neural Network	28
Gambar 4. 8 Plot countur dan loss during training	29

DAFTAR LAMPIRAN

Lampiran 1. 1 Code untuk metode explicit atau analitik pada persamaan gelombang.....	38
Lampiran 1. 2 Code perbandingan untuk neural network dan explicit	38
Lampiran 1. 3 Code metode Neural Network pada persamaan gelombang.....	40

BAB I PENDAHULUAN

A. Latar Belakang

Fisika adalah bidang ilmu pengetahuan yang berusaha memahami fenomena alam dan menguraikannya ke dalam bentuk pola pikir yang logis. Fisika teoretis dan eksperimen membentuk teori tentang fenomena alam. Selain dua metode sebelumnya, ada pendekatan ketiga untuk mempelajari sistem fisik yaitu fisika komputasi. Fisika komputasi mempelajari fenomena alam ini dengan menggunakan analisis numerik. Dalam ilmu fisika, matematika, teknik, dan bidang-bidang yang terkait, gelombang adalah gangguan yang merambat secara dinamis dari satu atau lebih parameter (Pain 2005). dalam kehidupan sehari-hari gelombang merupakan fenomena yang muncul dalam berbagai bidang ilmu pengetahuan dan teknologi, mulai dari gelombang elektromagnetik hingga gelombang mekanik. Gelombang elektromagnetik merupakan gelombang yang merambat secara bergelombang melalui beberapa variabel karakteristik seperti panjang gelombang, amplitudo dan frekuensi. Sedangkan gelombang mekanik dapat merambat melalui perantara seperti gelombang transversal dan longitudinal yang memiliki proses perambatan pada tali atau suara melalui medium udara atau benda lain. Persamaan gelombang merupakan bagian yang sangat penting dalam ilmu pengetahuan dan matematika terapan yang memiliki banyak aplikasi seperti analisis perambatan gelombang, akustik dan dinamika. Dalam kasus persamaan gelombang, kita dapat menemukan solusinya dengan menggunakan persamaan diferensial parsial (Alkhadhr and Almekawy 2023). Persamaan gelombang adalah persamaan diferensial parsial linier orde dua yang digunakan untuk menggambarkan perambatan gelombang dalam fisika klasik, seperti gelombang mekanik (contohnya gelombang dalam air, gelombang suara, dan gelombang seismik) atau gelombang elektromagnetik (termasuk gelombang cahaya) (Chasamah, Jamhuri, and Alisah 2021; Mahmoodi, Ghassemi, and Heydarian 2017). Persamaan diferensial parsial linier atau nonlinier memiliki berbagai macam aplikasi dalam fisika dan teknik. Persamaan diferensial parsial hiperbolik memodelkan getaran struktur (misalnya bangunan dan mesin)

dan merupakan dasar dari persamaan umum fisika atomik (Mirzaee and Bimesl 2013).

Hubungan yang saling terkait antara gelombang dan lingkungannya membuat pemodelan dan prediksi perilaku gelombang menjadi masalah yang menarik. Penggunaan metode konvensional untuk menyelesaikan persamaan gelombang sering kali membutuhkan asumsi yang sangat sederhana dan tidak memadai untuk memodelkan situasi dunia nyata. Sehingga, Penelitian ini bertujuan untuk mengembangkan metode baru dalam memodelkan persamaan gelombang dengan menggunakan pendekatan *Neural Network*. *Neural Network* dapat menyelesaikan masalah matematis yang kompleks dan dapat diaplikasikan dalam konteks persamaan gelombang. Dengan *Neural Network* diharapkan dapat memperoleh solusi yang lebih akurat dan memprediksi perilaku gelombang dalam kondisi yang nyata (Hsieh and Tang 1998)(Deo and Sridhar Naidu 1999). Persamaan gelombang dapat diselesaikan dengan melalui metode *Neural Network*, penyelesaian secara numerik dengan metode *Neural Network* juga dilakukan sebagai salah satu solusi terbaru dalam pemodelan matematika secara komputasi (Hughes et al. 2019). Metode *Neural Network* dapat digunakan untuk memprediksi dan memodelkan permasalahan dalam persamaan gelombang. Dalam menemukan solusi komputasi untuk persamaan gelombang, perlu diperhatikan kondisi stabilitas numerik. Dalam hal ini, menggunakan pendekatan *finite difference explicit* untuk kasus persamaan gelombang. Dengan menggunakan *Neural Network* kita dapat memastikan stabilitas dalam solusi *finite difference explicit* pada persamaan gelombang (Lines, Slawinski, and Phillip Bording n.d.).

Dalam menyelesaikan permasalahan tentang persamaan gelombang satu dimensi, dapat membandingkan solusi numerik terhadap metode *Neural Network*. *Neural Network* dengan kemampuannya digunakan untuk mempelajari pola dan hubungan dalam data yang akan di input. Karena, *Neural Network* dapat memberikan prediksi dari input ke output, berupa penggambaran grafik yang menampilkan bagaimana pola gelombang dari waktu ke waktu dan dari ruang ke ruang (Hosni Elhewy, Mesbahi, and Pu 2006). Hal ini tidak hanya membantu dalam memahami prinsip-prinsip yang mendasari persamaan, tetapi juga mengidentifikasi

variabel-variabel atau parameter yang mempengaruhi perilaku gelombang. Dengan menggunakan metode *Neural Network* diharapkan dapat memahami dan memvisualisasikan bentuk gelombang dari berbagai permasalahan. *Neural Network* memiliki struktur yang terdiri dari *input layer*, *hidden layer*, dan *output layer*. *Input layer* dalam *Neural Network* adalah berisikan variabel acak dasar atau data dari luar, sedangkan *output layer* digunakan untuk membangun fungsi keadaan batas yang diprediksi atau hasil pemrosesan data. Pada *hidden layer* digunakan untuk pemrosesan atau pemodelan data dengan fungsi matematika tertentu. *Hidden layer* pada metode *Neural Network* memiliki peran penting dalam memungkinkan model untuk mempelajari hubungan yang sangat kompleks antara input dan output (Anon n.d.-b).

Permasalahan Persamaan diferensial parsial dapat diselesaikan menggunakan neural network dengan penerapan NeuroDiffq dan jenis solusi lainnya, seperti DeepXDE. NeuroDiffq adalah salah satu hal terbaru dalam *Neural Network* untuk memecahkan Persamaan Diferensial Parsial. sementara itu DeepXDE memiliki banyak kelebihan dan kekurangan (Chen et al. 2020). Melalui pendekatan ini, diharapkan dapat memberikan solusi yang lebih akurat dan efisien. Dalam proses *Neural Network* solusi numerik pada persamaan gelombang akan di proses dalam struktur *Neural Network* sehingga, diharapkan dengan menggunakan *Neural Network* akan menghasilkan solusi yang paling efisien untuk berbagai algoritma pembelajaran (Akthar 2016). Lebih tepatnya, menggunakan *Physics-informed Neural Networks* (PINNs) dapat digunakan untuk menyelesaikan persamaan diferensial bersama dengan data awal dan batas yang ditentukan, dan dengan demikian dapat dilihat sebagai pendekatan alternatif untuk menyelesaikan persamaan diferensial dibandingkan dengan pendekatan numerik tradisional seperti metode *finite difference* (Bihlo and Popovych 2021). Untuk mendapatkan solusi numerik persamaan diferensial dapat memperkirakan parameter yang digunakan dalam persamaan diferensial. Kemampuan memodelkan metode numerik berguna mengidentifikasi berbagai jenis aliran gelombang dan memberikan solusi yang didapatkan melalui *Physics-informed Neural Networks* (PINNs) (Cedillo et al. 2022).

Dalam penelitian ini, dipilih persamaan gelombang satu dimensi, karena persamaan ini sering muncul dalam kehidupan sehari-hari. Contohnya adalah gelombang satu dimensi yang terjadi pada alat musik gitar dan piano. Penelitian ini menyajikan solusi dari persamaan gelombang satu menggunakan metode finite difference dan metode neural network. Sedangkan, bahasa pemrograman bahasa pemrograman yang dipilih adalah bahasa pemrograman Jupyter notebook. Dengan menggabungkan kedua model finite difference dan neural network diharapkan dapat menyelesaikan persamaan gelombang satu dimensi, pada metode neural network kita dapat menganalisis persamaan dengan variasi variabel untuk memprediksi hal yang ingin kita ketahui, baik itu mengenai kelebihan dan kekurangan model yang dibandingkan dengan teknik-teknik lain untuk menyelesaikan persamaan gelombang.

B. Rumusan Masalah

Berdasarkan uraian dasar yang telah diberikan. Sebuah masalah dapat dirumuskan dalam bentuk pertanyaan berikut :

1. Bagaimana penerapan metode finite difference explicit dan metode neural network dalam memecahkan persamaan gelombang satu dimensi?
2. Seberapa efektif dan akurat penerapan metode neural network dalam memodelkan perilaku gelombang satu dimensi dibandingkan dengan metode numerik tradisional seperti finite difference explicit?

C. Tujuan Penelitian

Berdasarkan perumusan masalah diatas, tujuan yang ingin dicapai dari pengkajian ini adalah :

1. Untuk menganalisis dan membandingkan proses penerapan metode finite difference explicit dan metode neural network dalam memecahkan persamaan gelombang satu dimensi.
2. Untuk mengukur efektivitas dan akurasi metode neural network dalam memodelkan perilaku gelombang satu dimensi. dan membandingkan hasil dari penerapan metode neural network dengan metode numerik tradisional, khususnya

finite difference explicit, dalam konteks perolehan solusi yang akurat dan dalam waktu komputasi yang efisien.

D. Manfaat Penelitian

Manfaat Penelitian ini adalah :

1. Memberikan pemahaman yang mendalam tentang perbandingan antara metode finite difference explicit dan neural network dalam menyelesaikan persamaan gelombang satu dimensi.
2. Menyediakan evaluasi tentang efektivitas dan akurasi metode neural network dalam memodelkan perilaku gelombang, serta membandingkannya dengan metode numerik tradisional seperti finite difference explicit.
3. Memberikan panduan praktis bagi peneliti dan praktisi dalam memilih metode yang paling sesuai untuk menyelesaikan persamaan gelombang satu dimensi, dengan mempertimbangkan kebutuhan akurasi dan efisiensi waktu komputasi.
4. Berkontribusi terhadap perkembangan ilmu pengetahuan dan teknologi dengan memperluas pemahaman tentang potensi aplikasi metode neural network dalam pemodelan perilaku gelombang satu dimensi, yang dapat mendorong inovasi dalam pendekatan penyelesaian masalah fisika yang kompleks.

E. Sistematika Penulisan

Adapun sistematika dalam penulisan skripsi ini mencakup beberapa bab dan subbab seperti dijelaskan di bawah ini:

1. BAB I Pendahuluan

Bab ini terdiri atas latar belakang, rumusan masalah, tujuan penelitian, manfaat penelitian, dan sistematika penulisan.

2. BAB II Landasan Teori

Bab ini terdiri dari pembahasan mengenai persamaan gelombang satu dimensi, metode *finite difference*, dan metode *neural network*.

3. BAB III Metode Penelitian

Bab ini terdiri atas studi kasus penerapan persamaan gelombang satu dimensi, metode *finite difference*, dan metode *neural network*.

4. BAB IV Hasil Penelitian dan Pembahasan

Bab ini terdiri atas penerapan dan pembahasan metode *finite difference* dan metode *neural network* terhadap persamaan gelombang satu dimensi dan manfaat bagi bidang Pendidikan.

5. BAB V Kesimpulan dan Saran

Bab ini berisi kesimpulan yang diperoleh dari bab sebelumnya yaitu hasil penelitian dan pembahasan terkait tujuan dari penelitian serta saran yang diberikan untuk kajian lebih lanjut dari skripsi ini.

BAB II

LANDASAN TEORI

A. Persamaan Gelombang Satu Dimensi

Persamaan gelombang adalah persamaan diferensial parsial linear orde dua dengan menggambarkan gelombang seperti gelombang air, gelombang suara, dan gelombang seismik) atau gelombang Cahaya (Atiyait, Bott, and ~rding n.d.). Persamaan ini juga ditemukan dalam bidang seperti dinamika fluida, akustik, dan elektromagnetik. Persamaan gelombang satu dimensi merupakan persamaan diferensial parsial yang dapat digunakan untuk menggambarkan gelombang dalam satu dimensi, dan juga dapat diselesaikan dengan menggunakan metode analitis dan numerik (Sabda Budi Prasetya and Puteri Kinasih n.d.). Banyak metode analitik yang digunakan untuk mendapatkan solusi analitik, sedangkan metode numerik salah satunya menggunakan metode finite difference untuk mendapatkan solusi numerik. Persamaan gelombang satu dimensi banyak diimplikasikan dalam berbagai konteks, termasuk dalam konsep fisika, hidrodinamika, dan mekanika kuantum. Dalam kaitannya dengan Persamaan diferensial banyak ilmuwan dan peneliti menggunakannya untuk menyelesaikan fenomena fisika dan kimia yang banyak dijumpai di sekitar kita atau dalam kehidupan sehari - hari. oleh karena itu persamaan diferensial memiliki peranan yang sangat penting untuk memodelkan fenomena-fenomena tersebut dan mendapatkan solusinya (Anon n.d.-a). Misalnya pada suatu penelitian menjelaskan bahwa gelombang satu dimensi yang terjadi pada sebuah dawai elastis yang diregangkan. Hasilnya, gelombang terbentuk dari getaran tali elastis berbentuk huruf L dengan kedua ujungnya terikat, ditarik atau diganggu, lalu dilepaskan secara bersamaan. Menentukan simpangan gelombang di titik mana pun dan waktu tertentu menjadi fokus. Untuk mempermudah, asumsi diterapkan panjang tali tetap, sangat elastis, dan tidak menawarkan resistensi. Lenturan atau tegangan yang dihasilkan oleh peregangan tali sebelum terikat lebih besar dari gaya gravitasi. Sedangkan untuk gerakan lateral tali dalam bidang vertikal diabaikan (Anon n.d.-a).

Pada penelitian sebelumnya, terdapat tinjauan sistem fisis pada sebuah dawai gitar Panjang L , keduanya ujungnya berada pada posisi simpangan nol. Untuk Persamaan gelombang satu dimensi pada senar menurut:

$$\frac{\partial^2 y}{\partial x^2} = \frac{1}{c^2} \frac{\partial^2 y}{\partial t^2} \quad (1)$$

Persamaan (1) adalah persamaan gelombang yang berlaku pada gelombang suara yang terjadi pada alat musik gitar, piano, dan lain-lain (Sabda Budi Prasetya and Puteri Kinasih n.d.). Banyak hal-hal yang terjadi dalam kehidupan sehari-hari dapat dimodelkan secara matematis yang disajikan ke dalam bentuk persamaan diferensial. Salah satu permasalahan fisika yang sering dijumpai adalah permasalahan gelombang. Persamaan gelombang merupakan persamaan dalam konsep matematika dan fisika yang sangat penting dan memiliki beragam aplikasi dalam berbagai bidang ilmu pengetahuan. Terdapat berbagai permasalahan yang berkaitan dengan persamaan gelombang, salah satunya adalah persamaan diferensial parsial gelombang satu dimensi.

Dalam fisika, gelombang adalah perambatan energi atau informasi melalui suatu medium. Contohnya adalah gelombang suara yang merambat melalui udara atau gelombang pada dawai yang bergetar. Pada persamaan gelombang satu dimensi, variabel seperti waktu, posisi, dan amplitudo gelombang dimodelkan secara matematis. Persamaan ini membuat para ilmuwan dan peneliti dapat memprediksi sifat-sifat gelombang, seperti frekuensi, panjang gelombang, dan kecepatan rambat dalam medium tertentu. Dengan memahami persamaan gelombang satu dimensi, kita dapat menjelaskan berbagai fenomena, mulai dari getaran pada senar gitar hingga perambatan gelombang seismik di kerak bumi. Persamaan ini juga penting dalam banyak aplikasi teknologi modern, termasuk komunikasi nirkabel, pemrosesan sinyal, dan gambar medis. Meskipun terlihat rumit, pemahaman dasar tentang persamaan gelombang satu dimensi dapat memberikan manfaat yang besar dalam kehidupan sehari-hari.

B. Metode Finite Difference

Analisis secara numerik, metode *finite difference* adalah suatu teknik numerik untuk menyelesaikan persamaan diferensial dengan cara pendekatan turunan dengan beda hingga. Terjadi terhadap ruang dan waktu yang didiskritisasi, atau dipecah menjadi sejumlah interval terbatas dan nilai solusi pada titik akhir interval didekati dengan menyelesaikan persamaan aljabar yang terdapat beda hingga dan nilai dari titik terdekat (Stynes n.d.).

Metode *finite difference* mengubah persamaan diferensial biasa (ODE) atau persamaan diferensial parsial (PDE), yang mungkin tidak linier, menjadi sistem persamaan linier yang dapat diselesaikan dengan teknik aljabar matriks. Pemrograman computer terbaru dapat melakukan komputasi aljabar linier ini secara efisien membuat kemudahan dalam mengimplementasikan. Sehingga, menyebabkan banyak penggunaan metode *finite difference* dalam analisis numerik (Stynes n.d.).

Persamaan diferensial secara umum dapat diselesaikan secara analitik, namun pada kenyataannya dalam beberapa kasus, menentukan solusi secara analitik merupakan hal yang cukup rumit dan membutuhkan waktu. Oleh karena itu, pendekatan secara numerik menjadi alternatif pilihan dalam menentukan solusi persamaan diferensial. Dalam penyelesaian dengan pendekatan model matematika, Selalu didasarkan pada metode dan teorema yang telah diuji secara ilmiah ketika menggunakan pendekatan model matematika untuk penyelesaian. Menurut (Munir 2003), metode numerik adalah cara untuk mendapatkan solusi yang lebih dekat ke solusi sebenarnya. Di sisi lain, metode analitik digunakan untuk menyelesaikan masalah sehingga diperoleh solusi yang tepat. Tiga metode utama dalam metode numerik dikenal: metode finite difference, finite element, dan spectral. Untuk metode beda hingga dan elemen hingga, logika ekspansi deret Taylor digunakan. Untuk metode spektral, logika interpolasi dan transformasi digunakan. Menurut (Kersale 2002), pendekatan penyelesaian persamaan diferensial dengan kesalahan yang berbeda akan dihasilkan dengan menggunakan pendekatan teori yang berbeda dari masing-masing metode (Hakim and Habibi 2016).

Pada penelitian sebelumnya, selain pada gelombang air satu dimensi juga terdapat pada masalah air tanah. Banyak faktor fisik dan kimiawi yang mempengaruhi lokasi bawah permukaan, yang dapat mengubah sifat-sifat air tanah. Sifat dan karakteristik air tanah dapat ditentukan dengan menggunakan berbagai model perhitungan. Salah satunya adalah model numerik, yang dibangun dengan menggunakan metode finite difference, yang memberikan nilai parameter hidrogeologi pada titik-titik atau node di dalam suatu domain (Trijayanti, Cahyadi, and Ernawati 2022). Finite Difference adalah penjabaran dari persamaan Laplace yang didasarkan pada gagasan blok tiga dimensi. Karena itu, simulasi model yang efektif diperlukan untuk dibuat dengan menggunakan perangkat lunak khusus, seperti Jupyter notebook.

Metode finite difference memiliki dua varian utama, yaitu eksplisit dan implisit, yang memiliki perbedaan dalam pendekatan penggunaan persamaan untuk menghitung nilai fungsi di titik-titik tertentu dalam ruang numerik. Metode finite difference eksplisit menggunakan persamaan yang menggantikan derivat dengan perbedaan antara nilai fungsi di titik berikutnya dan sebelumnya, sehingga lebih sederhana dan mudah diimplementasikan, namun tidak mampu menangani sistem dengan matriks koefisien yang tidak positif definit. Sedangkan, metode finite difference implisit menggunakan persamaan yang menggantikan derivat dengan perbedaan antara nilai fungsi di titik berikutnya dan sebelumnya, dikalikan dengan koefisien implisit. Meskipun lebih kompleks, metode ini memiliki kemampuan untuk menangani sistem yang memiliki matriks koefisien yang tidak positif definit. Contoh penelitian yang menggunakan kedua metode ini mencakup pemodelan aliran turbulensi (Gultom, A.S., 2018), analisis lendutan pada struktur balok (Tambunan, D.O., 2018), analisis kestabilan lereng (Kusuma Wardana et al. 2020) dan penentuan distribusi Specific Absorption Rate (SAR) pada jaringan tubuh (Ramadan M. et al. 2019). Dari contoh tersebut, metode finite difference implisit sering digunakan dalam penelitian yang membutuhkan stabilitas solusi untuk sistem yang kompleks, sementara metode finite difference eksplisit lebih cocok untuk aplikasi yang membutuhkan solusi yang lebih sederhana dan mudah diimplementasikan.

Metode finite difference gelombang satu dimensi adalah alat numerik yang penting untuk menyelesaikan persamaan gelombang satu dimensi dengan mengestimasi nilai fungsi pada titik-titik diskrit dalam ruang numerik. Metode ini memiliki aplikasi yang luas dalam memodelkan perambatan gelombang dalam berbagai konteks fisika. Dalam implementasinya, persamaan gelombang diferensial parsial diselesaikan dengan mengganti turunannya dengan selisih antara nilai fungsi pada titik-titik diskrit sebelumnya dan sesudahnya.

Metode finite difference dapat dilakukan secara eksplisit atau implisit, tergantung pada kompleksitas dan sifat sistem yang sedang dipelajari. Metode eksplisit lebih sederhana dan lebih mudah diimplementasikan, namun memiliki keterbatasan pada kestabilan solusi numeriknya, sedangkan metode implisit, meskipun lebih kompleks, lebih stabil dan dapat menangani sistem yang memiliki matriks koefisien yang tidak definit positif. Contoh penggunaan metode ini antara lain adalah pemodelan gelombang elektromagnetik pada antena mikrostrip dipole dan analisis defleksi dan tekuk pada balok prismatic dan non-prismatic, serta pemodelan penjarangan gelombang kejut melalui pipa berisi gas.

Dalam penelitian ini, Penggunaan metode beda hingga pada persamaan gelombang satu dimensi merupakan pendekatan numerik yang kuat untuk memodelkan perambatan gelombang dalam ruang numerik. Dengan menguraikan persamaan diferensial menjadi nilai fungsi beda pada titik-titik diskrit, metode ini memungkinkan analisis yang akurat dalam berbagai konteks fisik, seperti gelombang suara dan elektromagnetik. Dengan penerapan metode ini, para peneliti dapat memahami perilaku gelombang secara lebih mendalam dan merancang solusi untuk berbagai masalah teknik dan sains. Kemudahan metode eksplisit dan kestabilan metode implisit membuatnya menjadi alat yang sangat berguna dalam eksplorasi fenomena gelombang satu dimensi.

C. Metode Neural Network

Perkembangan saat ini machine learning atau disebut pembelajaran mesin, terdapat *neural network* merupakan model yang terinspirasi dari organisasi saraf pada jaringan saraf biologis yang ditemukan dalam otak hewan (Bishop n.d.).

Jaringan saraf tiruan ini terdiri dari unit-unit atau simpul yang terhubung yang disebut neuron buatan, yang secara kasar memodelkan fungsi neuron dalam otak. Neuron-neuron ini saling terhubung melalui ujung-ujungnya, meniru sinapsis dalam struktur otak. Neuron buatan menerima sinyal dari neuron terhubung, mengolahnya, dan mengirimkan sinyal ke neuron lain dalam jaringan. Setiap neuron menghitung outputnya dengan menggunakan fungsi non-linear dari total inputnya, yang dikenal sebagai fungsi aktivasi (Goel, Goel, and Kumar 2023). Bobot dan bias pada neuron dan sisi jaringan ini disesuaikan selama proses pembelajaran untuk meningkatkan kinerja jaringan.

Neural Network merupakan sistem jaringan pemrosesan yang terdiri dari beberapa neuron yang saling terkait. Neuron berfungsi untuk memecahkan masalah dari sebuah data. *Neural Network* sendiri digambarkan sebagai kemampuan menganalisis dan mengolah data pelatihan yang memiliki kemiripan dengan otak manusia. *Neural Network* digunakan untuk mendapatkan solusi numerik dari permasalahan persamaan differensial dan masalah nilai awal di berbagai bidang matematika, fisika, dan ilmu teknik.

Munculnya Artificial Neural Networks (ANNs) pada abad ke-20 diistilahkan seperti teori kerja neuron pada otak manusia. Hal ini sangat menarik untuk membuat suatu ide sejenis system yang mampu meniru teori kerja neuron yang disebut ANNs. Sekitar tahun 1970, penelitian ANN mengalami penyusutan karena tidak tersedia komputasi yang memadai dan teknik yang mampu mengkompensasi. Pada tahun 1969, menunjukkan bahwa ANNs tidak mampu menjalankan fungsi sebagai gerbang XOR.


Kemudian tahun 2005, ditemukan bahwa untuk meniru fungsi gerbang XOR, ANNs kurang banyak neuron (Vogels and Abbott 2005). Hal ini membuktikan bahwa keterbatasan jumlah neuron yang dapat dikomputasi sebab terbatasnya teknologi menghambat perkembangan ANNs di saat itu. Pada tahun 2012, Convolutional Neural Networks (CNNs) menjadi teknik yang umum digunakan dalam mendeteksi objek pada gambar, dengan penggunaan GPU, fungsi aktivasi ReLu, dan teknik dropout, setelah keberhasilan mengalahkan teknik terbaik (kedua) disaat itu dengan error setengah dari teknik tersebut (Krizhevsky,

Sutskever, and Hinton n.d.). Dalam pengembangan lebih lanjut, CNNs mampu mengalahkan akurasi manusia dalam identifikasi objek. Pada tahun 2015, AlphaGo dengan deep learning mampu mengalahkan juara dunia pada gim papan “Go”, dimana gim ini lebih rumit daripada catur. Saat ini, AI dengan ANNs dipandang mampu mempengaruhi ekonomi, pemasaran, hingga keputusan dan kepemimpinan (Huang and Rust 2018). Seiring perkembangan ANNs, muncul kembali sekitar tahun 2020 sebagai Physic-Informed Neural Networks (PINN) dan saat ini, penelitiannya terus berkembang. Hal ini didorong oleh pertimbangan untuk memperhitungkan ketidakpastian ketidakpastian dalam simulasi komputer selama dua dekade terakhir yang telah menyebabkan banyak parameter dengan rumus, sehingga rumus-rumus dalam permasalahan semakin rumit (Almqvist 2021). Sejauh ini, PINN telah diimplementasikan pada berbagai kasus seperti kasus fluida dan berbagai persamaan seperti: gelombang, perpindahan panas, dan Navier-Stokes.

Physics-Informed Neural Networks (PINN) adalah jaringan saraf (NN) yang mengubah dalam bentuk kode untuk model persamaan, seperti Persamaan Diferensial Parsial (PDE), sebagai komponen dari jaringan saraf itu sendiri. PINN saat ini digunakan untuk menyelesaikan PDE, persamaan pecahan, persamaan integral-diferensial, dan PDE stokastik. Physics-Informed Neural Networks (PINNs) adalah teknik pembelajaran mesin ilmiah yang digunakan untuk memecahkan masalah yang menggunakan Persamaan Diferensial Parsial (PDE). PINN mendekati solusi PDE dengan melatih jaringan saraf untuk meminimalkan fungsi kerugian. Hal ini termasuk istilah-istilah yang menggambarkan kondisi awal dan kondisi batas di sepanjang batas-batas domain ruang-waktu dan residu PDE pada titik-titik tertentu dalam domain (Cuomo et al. 2022).

PINN adalah jaringan pembelajaran mendalam yang menghasilkan solusi perkiraan dari persamaan diferensial pada titik input, dengan menambahkan beberapa layer untuk mempelajari persamaan fisika yang mengatur. Algoritma PINN mengubah penyelesaian persamaan diferensial parsial secara langsung menjadi masalah optimasi, dengan memasukkan model matematika ke dalam jaringan dan memperkuat fungsi kerugian dengan istilah sisa dari persamaan yang

mengatur. Hal ini memungkinkan algoritma ini untuk menemukan solusi PDE tanpa ketergantungan pada struktur jaringan tertentu, sehingga memberikan fleksibilitas yang besar dalam menangani berbagai macam masalah fisika.



Gambar 2. 1 kerangka neural network PINN

Gambar (1) merupakan skema neural network yang terhubung penuh digunakan untuk memperkirakan solusi (x, t) , yang digunakan untuk membentuk kerugian residual (L_r), kerugian kondisi batas (L_b), dan kerugian kondisi awal (L_0). Turunan dari (u) dihitung menggunakan diferensiasi otomatis di TensorFlow. Parameter dari jaringan yang terhubung penuh dilatih menggunakan metode gradien-descent berdasarkan propagasi balik dari fungsi kerugian. Skema pemilihan titik untuk PINN dalam domain komputasi ditunjukkan pada gambar, di mana titik-titik dengan warna yang berbeda sesuai dengan istilah yang berbeda dalam fungsi kerugian. Titik-titik residual untuk menghitung kerugian residual dapat dipilih secara acak dalam domain ruang-waktu (Cai et al. 2021).

Selain itu. Pada struktur *Neural Network* biasanya terdapat *input layer*, *hidden layer*, dan *output layer*. *Input layer* dalam *Neural Network* adalah berisikan variabel acak dasar atau data dari luar, sedangkan *output layer* digunakan untuk membangun fungsi keadaan batas yang diprediksi atau hasil pemrosesan data. Pada *hidden layer* digunakan untuk pemrosesan atau pemodelan data dengan fungsi matematika tertentu. *Hidden layer* pada metode *Neural Network* memiliki peran penting dalam memungkinkan model untuk mempelajari hubungan yang sangat kompleks antara input dan output (Abe, Miyao, and Kurita 2020). Sehingga, neural network terdiri dari beberapa lapisan, di mana setiap lapisan terdiri dari simpul-

simpul yang saling terhubung dan dilengkapi dengan fungsi aktivasi. Data dimasukkan ke jaringan melalui lapisan input, kemudian diproses melalui lapisan-lapisan yang berkomunikasi satu sama lain dengan bantuan koneksi berbobot. Setelah diproses, data tersebut diperoleh melalui lapisan output. Dengan struktur ini, jaringan mampu memproses dan menganalisis data dengan cara yang mirip dengan cara kerja otak manusia, meskipun dalam skala yang jauh lebih sederhana. Secara umum,

Input merupakan elemen utama dalam struktur jaringan syaraf, di mana data masukan diproses dan diubah menjadi hasil output melalui aktivasi unit. Hal ini dicapai dengan menerapkan fungsi yang disebut fungsi aktivasi, fungsi ambang batas atau fungsi transfer. Fungsi ini bertanggung jawab untuk mengubah nilai input menjadi nilai output dalam bentuk transformasi skalar ke skalar. Dengan kata lain, input net berperan dalam menginisiasi proses komputasi jaringan syaraf dan menentukan respons yang dihasilkan oleh unit-unit jaringan tersebut (Du et al. 2018). Pada ketiga proses layer tersebut terdapat juga fungsi aktivasi atau pembangkit dalam jaringan syaraf memainkan peran kunci dalam menentukan respons dari setiap neuron. Beberapa fungsi aktivasi umum termasuk *Binary Step Function* yang menghasilkan output biner berdasarkan ambang batas tertentu, *Linear* yang memberikan keluaran sebanding dengan inputnya, *Sigmoid* yang menghasilkan output dalam rentang 0 hingga 1, dan *Tanh* yang menghasilkan output dalam rentang -1 hingga 1. Selain itu, terdapat juga fungsi *ReLU* yang menghasilkan nol untuk nilai input negatif dan linear untuk nilai positif, *Leaky ReLU* yang memiliki gradien kecil untuk nilai negatif, *Parametrized ReLU* yang memungkinkan parameter tertentu diubah, *Exponential Linear Unit* yang memiliki keluaran yang lebih besar untuk nilai negatif, *Swish* yang merupakan pendekatan baru dengan non-linearitas lebih halus, dan *SoftMax* yang digunakan untuk output kelas-probabilitas dalam klasifikasi multikelas (Sharma, Sharma, and Athaiya 2020).

Neural network adalah model komputasi yang menggunakan input untuk menghasilkan output melalui serangkaian lapisan tersembunyi. Input diterima

melalui lapisan input, kemudian diproses melalui lapisan-lapisan tersembunyi yang mengandung neuron-neuron terhubung. Fungsi aktivasi, seperti *ReLU* atau *Sigmoid*, diterapkan di antara neuron untuk memperkenalkan non-linearitas dalam model. Ini memungkinkan jaringan untuk mempelajari pola yang kompleks dalam data. Pada akhirnya, output dihasilkan melalui lapisan output, yang memberikan prediksi atau informasi yang diinginkan berdasarkan input yang diberikan. Sehingga neural network menyediakan kerangka kerja yang kuat untuk memodelkan hubungan kompleks antara input dan output dalam data.

Physics-informed neural networks (PINNs) adalah Jaringan saraf yang diberitahukan oleh fisika (PINNs) merupakan jenis aproksimator fungsi universal yang mampu menyimpan pengetahuan tentang hukum fisika yang mengatur set data yang diberikan dalam proses pembelajaran, dan dapat diungkapkan melalui persamaan diferensial parsial (PDE) (Raissi, Perdikaris, and Karniadakis 2017). Metode ini mengatasi kurangnya data yang tersedia dalam beberapa sistem biologi dan teknik, yang membuat sebagian besar teknik pembelajaran mesin canggih kurang efektif dalam skenario ini. Pengetahuan sebelumnya tentang hukum fisika umum bertindak sebagai pengatur dalam *Neural Network*, membatasi ruang solusi yang dapat diterima, sehingga meningkatkan akurasi perkiraan fungsi (Raissi, Perdikaris, and Karniadakis 2019). Dengan demikian, memasukkan informasi sebelumnya ke dalam jaringan saraf akan meningkatkan isi informasi dari data yang tersedia, memungkinkan algoritma pembelajaran untuk menangkap solusi yang tepat dan menggeneralisasi dengan baik bahkan dengan jumlah contoh pelatihan yang rendah.

BAB III

METODE PENELITIAN

Dalam penelitian ini, menggunakan pendekatan gabungan antara metode finite difference dan neural network untuk menganalisis persamaan gelombang satu dimensi. Metode finite difference dapat menyelesaikan persamaan diferensial parsial dengan mendiskritisasi domain waktu dan ruang. Sehingga menemukan solusi pada titik-titik tersebut dengan menggunakan perbedaan nilai fungsi di sekitarnya. Metode neural network untuk memprediksi hasil yang lebih mendalam dengan input data yang sudah valid diproses dalam hidden kemudian ke output yang merupakan perkiraan solusi dari persamaan gelombang. Pendekatan gabungan ini diharapkan dapat memberikan keunggulan dalam memodelkan solusi persamaan gelombang dengan tingkat akurasi yang lebih tinggi dan kompleksitas yang lebih rendah dibandingkan dengan menggunakan metode secara terpisah. Metode ini akan diterapkan pada studi kasus tertentu dalam analisis gelombang satu dimensi guna menguji keefektifannya dalam menyelesaikan persoalan fisika yang kompleks. Mengenai persamaan gelombang merupakan hal yang sangat penting dalam penelitian khususnya dibidang fisika. Persamaan gelombang adalah bentuk diferensial parsial orde dua yang menggambarkan perambatan gelombang dalam suatu medium. Secara umum, persamaan gelombang digunakan untuk menjelaskan bagaimana gelombang melewati ruang dan waktu. Ada beberapa jenis persamaan gelombang, seperti persamaan gelombang mekanik untuk gelombang suara atau gelombang air, dan persamaan gelombang elektromagnetik untuk gelombang cahaya dan radio. Dengan memahami persamaan gelombang dapat diketahui bahwa terjadi beberapa hal dalam persamaan gelombang seperti memiliki perubahan gelombang dan pola arus gelombang. Adanya metode *Neural Network* akan mempermudah untuk mengembangkan model numerik yang dapat disimulasikan fenomena gelombang dengan akurat. Untuk persamaan umum dari persamaan diferensial parsial pada persamaan gelombang dapat diberikan menurut

$$\frac{\partial^2 u}{\partial t^2} = c^2 \frac{\partial^2 u}{\partial x^2} \quad (1)$$

dengan u merupakan posisi yang bergantung pada posisi lain x dan waktu t . Serta, kasus-kasus yang terkait dengan gelombang memiliki nilai awal dan syarat batas.

dengan nilai awal,

$$u(x, 0) = I(x)$$

$$\frac{\partial}{\partial t} u(x, 0) = f(t)$$

dengan syarat batas,

$$u(0, t) = 0$$

$$u(L, t) = 0$$

Solusi numerik digunakan untuk menyelesaikan persamaan diferensial parsial pada persamaan gelombang secara numerik. Metode numerik yang digunakan dalam penelitian ini adalah metode *finite difference explicit* dan metode *Neural Network*. mengenai persamaan gelombang dapat diselesaikan secara numerik dengan metode *finite difference explicit* menggunakan sumber dari penjabaran dari deret Taylor untuk menyelesaikan persamaan diferensial parsial pada persamaan gelombang.

Metode *finite difference* adalah pendekatan secara numerik untuk menyelesaikan persamaan diferensial parsial (PDE) seperti persamaan gelombang satu dimensi dengan mendiskretisasi domain waktu dan ruang menjadi titik-titik diskrit. Pendekatan ini memungkinkan aproksimasi solusi pada titik-titik diskrit dengan menggunakan perbedaan nilai fungsi di sekitarnya. Sedangkan, *neural network* dapat digunakan untuk memodelkan solusi persamaan gelombang dengan metode yang berbeda. Dalam konteks ini, *neural network* dapat dipelajari untuk memetakan input ke output yang merupakan perkiraan solusi dari persamaan gelombang.

Kedua metode ini memiliki pendekatan yang berbeda namun bertujuan sama, yaitu untuk memperoleh perkiraan solusi dari persamaan gelombang satu dimensi.

Finite difference memanfaatkan pendekatan numerik sederhana dengan diskritisasi ruang dan waktu, sementara neural network menggunakan pendekatan yang lebih kompleks dengan mempelajari pola pada data untuk menghasilkan solusi perkiraan. Dalam praktiknya, pemilihan metode tergantung pada kebutuhan komputasi, ketelitian yang diinginkan, serta kompleksitas dari persamaan yang ditangani. Dengan menggunakan metode *Neural Network* didapatkan solusi persamaan diferensial parsial pada persamaan gelombang secara modern atau dalam bidang fisika komputasi. Dengan menggabungkan metode *finite difference explicit* dan *Neural Network* dapat memperoleh solusi yang lebih akurat dan efisien dalam memahami pola perubahan perilaku gelombang satu dimensi.

BAB IV HASIL PENELITIAN DAN PEMBAHASAN

A. Hasil Penelitian

1. Penyelesaian metode finite difference explicit

Berdasarkan landasan teori yang dilakukan penulis, didapatkan penyelesaian analitik dan numerik. Dalam kasus persamaan gelombang satu dimensi yang dijabarkan pada persamaan (1), dapat kita tinjau dengan menggunakan metode *finite difference explicit*. Berdasarkan kondisi awal dan syarat batas yang akan digunakan, sehingga didapatkan persamaan *finite difference explicit* yang dihitung pada setiap waktu dan ruang. Sehingga didapatkan solusi untuk menyelesaikan persamaan diferensial parsial pada persamaan gelombang dengan diskritisasi persamaan (1) diuraikan menjadi

$$u_{tt} = \frac{u_j^{n+1} - 2u_j^n + u_j^{n-1}}{h_t^2} \quad (2)$$

$$u_{tt} = \frac{u_{j+1}^n - 2u_j^n + u_{j-1}^n}{h_x^2} \quad (3)$$

Sehingga,

$$\frac{u_j^{n+1} - 2u_j^n + u_j^{n-1}}{h_t^2} = c^2 \frac{u_{j+1}^n - 2u_j^n + u_{j-1}^n}{h_x^2} \quad (4)$$

Suku yang dicari adalah u_j^{n+1} yang diuraikan menurut

$$u_j^{n+1} = s(u_{j+1}^n + u_{j-1}^n) + 2(1-s)u_j^n - u_j^{n-1} \quad (5)$$

dengan $s = c^2 \frac{h_t^2}{h_x^2}$

Menggunakan penyelesaian diskritisasi turunan parsial dalam persamaan berikutnya perlu untuk membuat diskritisasi nilai awal

$$u(x, 0) = I(x) \rightarrow u_j^0 = I(x) \quad (6)$$

$$\frac{\partial}{\partial t} u(x, 0) = 0 \rightarrow \frac{u_j^1 - u_j^{-1}}{2h_t} = 0$$

$$u_j^1 = u_j^{-1} \quad (7)$$





Substitusikan persamaan (7) ke persamaan (1)

$$u_j^1 = \frac{s}{2}(u_{j+1}^0 + u_{j-1}^0) + (1-s)u_j^0 \quad (8)$$

Fungsi awal $I(x)$ yang diambil adalah

$$I(x) = e^{-k(x-x_0)^2} \quad (9)$$

Setelah berhasil menyelesaikan secara numerik dengan menggunakan metode *finite difference explicit*, selanjutnya melakukan validasi terhadap hasil yang diperoleh. Validasi ini penting dilakukan untuk memastikan kelayakan dan keakuratan hasil simulasi dalam merepresentasikan sebuah kejadian yang akan dimodelkan. Salah satu aspek yang perlu diuji adalah kestabilan hasil numerik. Secara umum, parameter yang digunakan dalam simulasi, seperti parameter kecepatan (v), dapat mempengaruhi kestabilan hasil. Berdasarkan penelitian sebelumnya, didapatkan bahwa untuk memastikan hasil yang stabil, nilai parameter v harus berada di bawah sebesar 1. Jika nilainya lebih dari sebesar 1.1, hasil yang didapatkan cenderung menjadi tidak stabil. Untuk memberikan pemahaman yang lebih mendalam mengenai perbedaan kestabilan tersebut, dapat dilihat pada gambar berikut. Gambar ini menunjukkan dampak perubahan nilai parameter v terhadap kestabilan hasil simulasi.


(a) parameter ν sebesar 1.1(b) parameter ν sebesar 1.0(c) parameter ν sebesar 0.5(d) parameter ν sebesar 0.1**Gambar 4. 1** hasil metode finite difference explicit

Dengan memperhatikan nilai-nilai tersebut, akan menjadi acuan penting dalam memvalidasi suatu persamaan menggunakan metode *finite difference explicit* dalam hal simulasi numerik. Dengan validasi yang tepat, hasil simulasi dapat diandalkan dan memberikan kontribusi yang berarti bagi pemahaman fenomena yang diteliti. Dari grafik yang stabil dan tidak stabil dapat memberikan informasi tentang bagaimana perubahan waktu setiap iterasi berpengaruh terhadap sistem.

2. Penyelesaian metode neural network





Dengan metode *Neural Network* juga dapat memvisualisasikan grafik fungsi pada setiap *time step*, untuk menganalisis pola perubahan nilai (Alguacil et

al. 2021). Grafik yang stabil akan menunjukkan perubahan yang terjadi pada setiap iterasi yang dapat diprediksi dan berulang-ulang terus dari waktu ke waktu. Sebaliknya, grafik yang tidak stabil dapat menunjukkan ketidakseimbangan atau perbedaan yang dapat mempengaruhi simulasi hasil akhir. Pada gambar (2) kita dapat mempelajari proses yang terjadi pada grafik dan memastikan bahwa simulasi numerik tidak hanya akurat, tetapi juga dapat diandalkan pada setiap tahap perhitungan. Sehingga, untuk memberikan visual dan pemahaman lebih baik tentang bagaimana perubahan yang terjadi terhadap kedua variabel ruang dan waktu. Dengan ini, untuk mendapatkan hasil yang valid diperlukan penyesuaian parameter untuk meningkatkan stabilitas hasil simulasi.







Gambar 4. 2 parameter v sebesar 1.1


Dalam gambar (3) beberapa grafik menunjukkan pengambilan data pada langkah waktu 0, 25, 50, dan 100, grafik menunjukkan variasi yang cukup signifikan. terdapat perbedaan yang cukup jauh pada langkah waktu ke-25 dan ke-50 dimana grafik pada memiliki banyak gelombang, sehingga hasilnya akan sulit untuk dianalisis.

(a) grafik pada *time 0*(b) grafik pada *time 25*(c) grafik pada *time 50*(d) grafik pada *time 100***Gambar 4. 3** parameter v sebesar 1.0

Pada gambar (4) beberapa grafik menunjukkan pengambilan data pada langkah waktu 0, 25, 50, dan 100. Dimana grafik menunjukkan hasil yang cukup baik dan beraturan. Akan tetapi belum masih belum stabil pada waktu ke-25 terdapat dua gelombang yang terjadi. Pada langkah waktu ke-50 dan ke-100 hasilnya juga tidak stabil dengan langkah waktu sebelumnya.

(a) grafik pada *time 0*(b) grafik pada *time 25*(c) grafik pada *time 50*(d) grafik pada *time 100***Gambar 4. 4** parameter v sebesar 0.5

Dalam gambar (5) beberapa grafik menunjukkan pengambilan data pada langkah waktu 0, 25, 50, dan 100. Dimana grafik menunjukkan hasil yang cukup baik dan beraturan. Akan tetapi belum stabil pada waktu ke-25 hampir terbentuk dua gelombang. Sedangkan, pada langkah waktu ke-50 dan ke-100 hasilnya stabil dengan langkah waktu sebelumnya. Namun, tidak sesuai dengan Langkah waktu ke-0 sehingga hasilnya masih belum stabil.




Gambar 4. 5 parameter v sebesar 0.1

Pada gambar (6), beberapa grafik menunjukkan pengambilan data pada langkah waktu 0, 25, 50, dan 100. Dimana grafik menunjukkan hasil yang baik dan stabil. Karena, pada Langkah waktu mulai dari 0 sampai 100 hampir berjalan stabil dan berturan. Sehingga hasil nantinya akan stabil dan nilai parameter yang stabil bisa digunakan untuk analisis selanjutnya. Hal ini menunjukkan bahwa pemilihan parameter, seperti nilai v memiliki dampak yang besar terhadap kestabilan grafik, dan penyesuaian parameter dapat memastikan hasil simulasi yang lebih akurat dan dapat diterima.

Setelah memastikan nilai parameter v yang membuat hasil metode *finite difference explicit* stabil, maka validitasnya dapat dianggap cukup terjamin. Dengan kemajuan teknologi, pendekatan baru seperti *Neural Network* mulai memiliki peran penting dalam simulasi numerik. *Neural Network* memberikan banyak keuntungan dalam menghadapi masalah yang kompleks dan dapat mengikuti pola-pola yang

rumit (Anitescu et al. 2019). Melalui perbandingan antara hasil metode *finite difference explicit* yang stabil dan prediksi yang diberikan oleh *Neural Network*, kita dapat memperoleh pemahaman yang lebih dalam tentang kelebihan dan kekurangan masing-masing metode dalam menyelesaikan persamaan gelombang satu dimensi.

Penggunaan *Neural Network* telah menjadi salah satu pendekatan utama untuk menyelesaikan berbagai masalah yang kompleks. Untuk penelitian ini dalam menyelesaikan permasalahannya digunakan Solusi penerapan neurodiffeq untuk mendapatkan pemahaman yang lebih mendalam dan penelitian sebelumnya banyak menerapkan deepXDE (Chen et al. 2020). Dalam penelitian lainnya, menjalankan *Neural Network* membutuhkan pemilihan jumlah iterasi atau *epochs* yang tepat untuk menyelesaikan masalah yang dihadapi. dimana penentuan *epochs* merupakan langkah penting untuk menyelesaikan masalah (Siahkoohi, Louboutin, and Herrmann 2019). Dalam kasus penelitian ini, hal yang utama adalah menyelesaikan persamaan gelombang. untuk melakukan berbagai percobaan dengan mengatur jumlah *epochs* yang berbeda, yaitu 1000, 5000, 10000, dan 20000. Dengan memvariasikan nilai *epochs*, maka dapat menyesuaikan model tersebut, sehingga menghasilkan keseimbangan antara *underfitting* dan *overfitting*. ketika, Jumlah *epochs* yang lebih rendah dapat menyebabkan *underfitting*, di mana model gagal menangkap kompleksitas data, sementara jumlah yang berlebihan dapat menyebabkan *overfitting*. Sehingga, dengan *epochs* tepat maka hasil yang didapatkan berupa valid terhadap solusi yang telah diselesaikan sebelumnya menggunakan solusi eksplisit (de Wolff et al. 2021).




Gambar 4. 6 Hasil Neural Network


B. Pembahasan

Dengan hasil dari analisis sebelumnya dapat dilakukan perbandingan hasil yang diperoleh dari metode *finite difference explicit* dan pendekatan *Neural Network* memberikan sebuah pemahaman berbeda. Setelah mendapatkan grafik hasil *Neural Network* yang hampir menyerupai metode *finite difference explicit*, kemudian bisa dipelajari lebih lanjut perbandingan antara keduanya. Grafik hasil *Neural Network* yang mendekati metode eksplisit merupakan sebuah prediksi bahwa model *Neural Network* berhasil meniru pola dan grafik yang terdapat pada metode *finite difference explicit*. Kemiripan grafik tersebut dapat memberikan


gambaran akan kemampuan pendekatan *Neural Network* dalam memodelkan persamaan gelombang satu dimensi. Dengan variasi *epochs* yang dilakukan hasil terbaik pada *epochs* 20000. Semakin banyak *epochs* yang dilakukan maka hasil prediksi terhadap persamaan gelombang semakin akurat dan teliti. Selanjutnya, kita perlu membandingkan perbedaan model visual dari hasil *finite difference explicit* dan *Neural Network*, dengan pengurangan dari kedua metode tersebut sehingga dapat diketahui bagian mana yang paling terlihat perbedaannya.




(a) *epochs* 1000



(b) *epochs* 5000




(c) *epochs* 10000



(d) *epochs* 20000

Gambar 4. 7 Selisih metode finite difference explicit dan Neural Network

Selain itu, penting untuk mengevaluasi kemampuan *Neural Network* melalui *training loss* dan *validation loss*. *Training loss* menunjukkan sejauh mana model dapat beradaptasi dengan data pelatihan, sedangkan *validation loss* mengukur sejauh mana model dapat menggeneralisasi data baru yang belum pernah dilihat (Sorteberg et al. 2018). Analisis tren *training loss* dan *validation loss* dapat memberikan pemahaman tentang stabilitas dan generalisasi model *Neural Network* dalam hal simulasi persamaan gelombang (Pratama et al. 2022). Oleh karena itu, perbandingan grafik dan mengevaluasi loss dapat menjadi langkah penting untuk menilai kemampuan dan akurasi pendekatan *Neural Network* dalam simulasi persamaan diferensial parsial.



Gambar 4. 8 Plot countur dan loss during training

C. Manfaat Bagi Bidang Pendidikan

Dengan adanya penelitian ini, sangatlah penting dalam perkembangan ilmu pengetahuan dan teknologi. Penelitian ini mengintegrasikan dua pendekatan yang berbeda dalam pemodelan persamaan gelombang, yaitu metode finite difference explicit dan neural network. Hasil dari penelitian ini diharapkan dapat memberikan wawasan yang mendalam tentang efektivitas kedua metode tersebut dalam

memprediksi gelombang satu dimensi. Dan menjadi referensi bagi mahasiswa terutama mahasiswa Pendidikan fisika dalam mempelajari persamaan differensial parsial dan pemahaman kita tentang aplikasi kecerdasan buatan dalam pemodelan matematika dan fisika. Dengan memahami dan menerapkan konsep ini, mahasiswa dan peneliti dapat meningkatkan keterampilan mereka dalam pemodelan fenomena fisik kompleks. Selain itu, pendekatan gabungan ini juga membuka pintu bagi penelitian lebih lanjut dalam pengembangan metode numerik yang lebih efisien dan akurat untuk memecahkan persamaan diferensial dalam berbagai bidang ilmu, seperti fisika, teknik, dan sains komputer. Dengan demikian, skripsi ini memiliki dampak positif yang signifikan dalam meningkatkan kualitas pendidikan dan pengembangan ilmu pengetahuan.

BAB V

KESIMPULAN DAN SARAN

A. Kesimpulan

Dalam penelitian ini, dapat disimpulkan bahwa penerapan metode *finite difference explicit* dan *Neural Network* dalam analisis persamaan gelombang satu dimensi memberikan pemahaman yang lebih menarik dan mendalam. Metode *finite difference explicit* memberikan kestabilan pada simulasi gelombang, sedangkan *Neural Network* memberikan kemampuan prediksi yang baik. Dengan menggabungkan keduanya, kita dapat memperoleh kelebihan dalam menganalisis dan memahami persamaan gelombang dengan lebih baik. Pendekatan ini memungkinkan penerapan yang lebih luas dalam simulasi gelombang yang kompleks, dan memberikan dasar bagi pengembangan teknologi prediksi yang lebih cepat. Kesimpulannya, penelitian ini merupakan langkah penting dalam menggabungkan metode lama dan pendekatan modern untuk pemahaman yang lebih mendalam tentang gelombang satu dimensi.

B. Saran

Dalam penelitian ini, terdapat sejumlah saran yang dapat diusulkan untuk penelitian masa depan. Pertama, penelitian dapat diperluas dengan membandingkan metode yang digunakan dengan metode lain dalam pemodelan persamaan gelombang. Selain itu, penggunaan data yang lebih kompleks atau situasi yang lebih realistis dapat memberikan pemahaman yang lebih mendalam tentang kinerja metode tersebut. Kedua, pengembangan algoritma neural network lebih lanjut dapat dilakukan untuk meningkatkan akurasi dan efisiensi dalam memprediksi gelombang satu dimensi. Integrasi dengan teknik optimasi yang lebih canggih juga dapat dieksplorasi untuk memperbaiki kinerja jaringan. Dengan menerapkan saran-saran ini, penelitian masa depan dapat memberikan kontribusi yang lebih besar dalam pengembangan metode numerik dan kecerdasan buatan dalam pemodelan fenomena fisik, membuka peluang baru untuk inovasi dan penemuan ilmiah yang lebih lanjut.

DAFTAR PUSTAKA

- Abe, Motoshi, Junichi Miyao, and Takio Kurita. 2020. "Adaptive Neuron-Wise Discriminant Criterion and Adaptive Center Loss at Hidden Layer for Deep Convolutional Neural Network."
- Akthar, Shaheda. 2016. *A Study on Neural Network Architectures*. Vol. 7.
- Alguacil, Antonio, Michaël Bauerheim, Marc C. Jacob, and Stéphane Moreau. 2021. "Predicting the Propagation of Acoustic Waves Using Deep Convolutional Neural Networks." *Journal of Sound and Vibration* 512. doi: 10.1016/j.jsv.2021.116285.
- Alkhadhr, Shaikhah, and Mohamed Almekkawy. 2023. "Wave Equation Modeling via Physics-Informed Neural Networks: Models of Soft and Hard Constraints for Initial and Boundary Conditions." *Sensors* 23(5). doi: 10.3390/s23052792.
- Almqvist, Andreas. 2021. "Fundamentals of Physics-Informed Neural Networks Applied to Solve the Reynolds Boundary Value Problem." *Lubricants* 9(8). doi: 10.3390/lubricants9080082.
- Anitescu, Cosmin, Elena Atroshchenko, Naif Alajlan, and Timon Rabczuk. 2019. "Artificial Neural Network Methods for the Solution of Second Order Boundary Value Problems." *Computers, Materials and Continua* 59(1):345–59. doi: 10.32604/cmc.2019.06641.
- Anon. n.d.-a. "1340-121-3153-1-10-20220303."
- Anon. n.d.-b. "Takayama1999."
- Atiyait, M. F., R. Bott, and L. G. / . ~rding. n.d. *LACUNAS FOR HYPERBOLIC DIFFERENTIAL OPERATORS WITH CONSTANT COEFFICIENTS I*.
- Bihlo, Alex, and Roman O. Popovych. 2021. "Physics-Informed Neural Networks for the Shallow-Water Equations on the Sphere." doi: 10.1016/j.jcp.2022.111024.
- Bishop, Christopher M. n.d. *Pattern Recognition and Machine Learning*.

- Cai, Shengze, Zhicheng Wang, Sifan Wang, Paris Perdikaris, and George Em Karniadakis. 2021. “Physics-Informed Neural Networks for Heat Transfer Problems.” *Journal of Heat Transfer* 143(6). doi: 10.1115/1.4050542.
- Cedillo, Sebastián, Ana Gabriela Núñez, Esteban Sánchez-Cordero, Luis Timbe, Esteban Samaniego, and Andrés Alvarado. 2022. “Physics-Informed Neural Network Water Surface Predictability for 1D Steady-State Open Channel Cases with Different Flow Types and Complex Bed Profile Shapes.” *Advanced Modeling and Simulation in Engineering Sciences* 9(1). doi: 10.1186/s40323-022-00226-8.
- Chasamah, Allifia Nur, Muhammad Jamhuri, and Evawati Alisah. 2021. “Solusi Numerik Persamaan Gelombang Dua Dimensi Dengan Metode Beda Hingga Skema Eksplisit CTCS.” *Jurnal Riset Mahasiswa Matematika* 1(1):14–22. doi: 10.18860/jrmm.v1i1.13411.
- Chen, Feiyu, David Sondak, Pavlos Protopapas, Marios Mattheakis, Shuheng Liu, Devansh Agarwal, and Marco Di Giovanni. 2020. “NeuroDiffEq: A Python Package for Solving Differential Equations with Neural Networks.” *Journal of Open Source Software* 5(46):1931. doi: 10.21105/joss.01931.
- Cuomo, Salvatore, Vincenzo Schiano Di Cola, Fabio Giampaolo, Gianluigi Rozza, Maziar Raissi, and Francesco Piccialli. 2022. “Scientific Machine Learning Through Physics–Informed Neural Networks: Where We Are and What’s Next.” *Journal of Scientific Computing* 92(3). doi: 10.1007/s10915-022-01939-z.
- Deo, M. C., and C. Sridhar Naidu. 1999. *Real Time Wave Forecasting Using Neural Networks*. Vol. 26.
- Du, Simon S., Jason D. Lee, Yuandong Tian, Barnabás Póczos, and Aarti Singh. 2018. *Gradient Descent Learns One-Hidden-Layer CNN: Don’t Be Afraid of Spurious Local Minima*.
- Goel, Akash, Amit Kumar Goel, and Adesh Kumar. 2023. “The Role of Artificial Neural Network and Machine Learning in Utilizing Spatial Information.” *Spatial Information Research* 31(3):275–85.

- Hakim, Lukman, and Azwar Riza Habibi. 2016. *Perbandingan Skema Numerik Metode Finite Difference Dan Spectral*. Vol. 10.
- Hosni Elhewy, A., E. Mesbahi, and Y. Pu. 2006. "Reliability Analysis of Structures Using Neural Network Method." *Probabilistic Engineering Mechanics* 21(1):44–53. doi: 10.1016/j.probengmech.2005.07.002.
- Hsieh, William W., and Benyang Tang. 1998. *Applying Neural Network Models to Prediction and Data Analysis in Meteorology and Oceanography*.
- Huang, Ming Hui, and Roland T. Rust. 2018. "Artificial Intelligence in Service." *Journal of Service Research* 21(2):155–72. doi: 10.1177/1094670517752459.
- Hughes, Tyler W., Ian A. D. Williamson, Momchil Minkov, and Shanhui Fan. 2019. *A P L I E D P H Y S I C S Wave Physics as an Analog Recurrent Neural Network*.
- Krizhevsky, Alex, Ilya Sutskever, and Geoffrey E. Hinton. n.d. *ImageNet Classification with Deep Convolutional Neural Networks*.
- Kusuma Wardana, Novandri, Meda Rusdiana Ipmawati, Noviana Pratiwi, Program Studi Teknik Pertambangan, Fakultas Teknologi Mineral ITNY, PPSDM Geominerba Bandung, Program Studi Statistika, Fakultas Sains Terapan, and Ist Akprind Yogyakarta. 2020. *Analisis Rekah Tarik Lereng Sidewall Penambangan Blok Menyango Berdasarkan Reliabilitas Kemantapan Lereng Menggunakan Metode Finite Difference (Slope Tensile Fracture Analysis of Menyango Block Mining Based on Slope Stability Reliability Using the Finite Difference Method)*. Vol. 8.
- Lines, Larry R., Raphael Slawinski, and R. Phillip Bording. n.d. *Short Note A Recipe for Stability of Finite-Difference Wave-Equation Computations*. Vol. 64.
- Mahmoodi, Kumars, Hassan Ghassemi, and Alireza Heydarian. 2017. "Solving the Nonlinear Two-Dimension Wave Equation Using Dual Reciprocity Boundary Element Method." *International Journal of Partial Differential Equations and Applications* 5(1):19–25. doi: 10.12691/ijpdea-5-1-3.

- Mirzaee, Farshid, and Saeed Bimesl. 2013. “A New Approach to Numerical Solution of Second-Order Linear Hyperbolic Partial Differential Equations Arising from Physics and Engineering.” *Results in Physics* 3:241–47. doi: 10.1016/j.rinp.2013.10.002.
- Pain, H. J. (Herbert John). 2005. *The Physics of Vibrations and Waves*. John Wiley.
- Pratama, Danang A., Maharani A. Bakar, N. B. Ismail, and M. Mashuri. 2022. “ANN-Based Methods for Solving Partial Differential Equations: A Survey.” *Arab Journal of Basic and Applied Sciences* 29(1):233–48.
- Raissi, M., P. Perdikaris, and G. E. Karniadakis. 2019. “Physics-Informed Neural Networks: A Deep Learning Framework for Solving Forward and Inverse Problems Involving Nonlinear Partial Differential Equations.” *Journal of Computational Physics* 378:686–707. doi: 10.1016/j.jcp.2018.10.045.
- Raissi, Maziar, Paris Perdikaris, and George Em Karniadakis. 2017. “Physics Informed Deep Learning (Part I): Data-Driven Solutions of Nonlinear Partial Differential Equations.”
- Sabda Budi Prasetya, Dwi, and Indira Puteri Kinasih. n.d. *KAJIAN GELOMBANG SATU DIMENSI BERDASARKAN HASIL KOMPUTASI NUMERIK*. Vol. 2.
- Sharma, Siddharth, Simone Sharma, and Anidhya Athaiya. 2020. *ACTIVATION FUNCTIONS IN NEURAL NETWORKS*. Vol. 4.
- Siahkoohi, Ali, Mathias Louboutin, and Felix J. Herrmann. 2019. “Neural Network Augmented Wave-Equation Simulation.”
- Sorteberg, Wilhelm E., Stef Garasto, Alison S. Pouplin, Chris D. Cantwell, and Anil A. Bharath. 2018. “Approximating the Solution to Wave Propagation Using Deep Neural Networks.”
- Stynes, Martin. n.d. *Christian Grossmann Hans-Görg Roos Numerical Treatment of Partial Differential Equations Universitext*.

- Trijayanti, Hana, Agung Cahyadi, and Rika Ernawati. 2022. *Aplikasi Penggunaan Metode Finite Difference Dalam Pemodelan Air Tanah Pada Kasus Pertambangan : Literatur Review Application of the Finite Difference Method in Groundwater Modeling in Mining Cases: Literature Review*. Vol. 7.
- Vogels, Tim P., and L. F. Abbott. 2005. "Signal Propagation and Logic Gating in Networks of Integrate-and-Fire Neurons." *Journal of Neuroscience* 25(46):10786–95. doi: 10.1523/JNEUROSCI.3508-05.2005.
- de Wolff, Taco, Hugo Carrillo, Luis Martí, and Nayat Sanchez-Pi. 2021. "Towards Optimally Weighted Physics-Informed Neural Networks in Ocean Modelling."

LAMPIRAN

```

from numpy import *
from matplotlib.pyplot import *
from matplotlib.ticker import LinearLocator
from mpl_toolkits.mplot3d import axes3d
X_m = 10
T_m = 10
v = 0.1
xe, hx = linspace(0, X_m, 100, retstep=True)
te, ht = linspace(0, T_m, 180, retstep=True)
s=(v*ht/hx)**2
#nilai awal
def I(x):
    u = exp(-0.2*(x-5)**2)
    return u
def g(x):
    G=0.
    return G
U = zeros((len(xe),len(te)))
#syarat batas
U[0,:]= 0
U[-1,:]= 0
U[:,0] = I(xe)
#Perhitungan step tambahan persamaan 5
for j in range(1, len(xe)-1):
    U[j,1]=s/2*(U[j+1,0]+U[j-1,0])+(1-s)*U[j,0]
for n in range(1, len(te)-1):
    for j in range(1, len(xe)-1):
        U[j,n+1]=s*(U[j+1,n]+U[j-1,n])+2*(1-s)*U[j,n]-U[j,n-1]

```

```
fig = figure(figsize=(6,2))
ax = subplot()
ax.plot(xe,U[:,99])
ax.set_xlabel('x(m)')
ax.set_ylabel('y(m)')
ax.legend(title='time 100')
grid('on')
```

Lampiran 1 1 Code untuk metode explicit atau analitik pada persamaan gelombang

```
xs = np.linspace(0, L, 100)
ts = np.linspace(0, T, 100)
xx, tt = np.meshgrid(xs, ts)
sol_net = solution_neural_net_heat(xx, tt, to_numpy=True)

fig = figure(figsize=(6,6))
ax = fig.add_subplot(111, projection='3d')
ax.plot_surface(xx, tt, U.T-sol_net, cmap='magma')
```

Lampiran 1 2 Code perbandingan untuk neural network dan explicit

```

import numpy as np
import torch
from torch import nn
from torch import optim
from neurodiffeq import diff
from neurodiffeq.networks import FCNN, SinActv
from neurodiffeq.pde import solve2D, Monitor2D
from neurodiffeq.generators import Generator2D, PredefinedGenerator
from neurodiffeq.conditions import IBVP1D
from neurodiffeq.pde import make_animation
from neurodiffeq.solvers import Solver2D
from mpl_toolkits.mplot3d import Axes3D
from matplotlib.pyplot import *
from matplotlib.ticker import LinearLocator

k, L, T = 0.1, 10, 10
# Define the PDE system
# There's only one (wave) equation in the system, so the function maps (u, x, y) to a
single entry
heat = lambda u, x, t: [
    diff(u, t, order=2) - k * diff(u, x, order=2)
]

# Define the initial and boundary conditions
# There's only one function to be solved for, so we only have a single condition object
conditions = [
    IBVP1D(
        t_min=0, t_min_val=lambda x: torch.exp(-(x-5)**2),
        x_min=0, x_min_prime=lambda t: 0,
        x_max=L, x_max_prime=lambda t: 0
    )
]

# Define the neural network to be used
# Again, there's only one function to be solved for, so we only have a single network
nets = [
    FCNN(n_input_units=2, hidden_units=(100, 100, 100), actv=SinActv)
]

# Define the monitor callback
monitor=Monitor2D(check_every=10000000000000, xy_min=(0, 0), xy_max=(L, T))
monitor_callback = monitor.to_callback()

```

```

# Instantiate the solver
solver = Solver2D(
    pde_system=heat,
    conditions=conditions,
    xy_min=(0, 0), # We can omit xy_min when both train_generator and
valid_generator are specified
    xy_max=(L, T), # We can omit xy_max when both train_generator and
valid_generator are specified
    nets=nets,
    train_generator=Generator2D((32, 32), (0, 0), (L, T), method='equally-spaced-noisy'),
    valid_generator=Generator2D((32, 32), (0, 0), (L, T), method='equally-spaced'),
)

# Fit the neural network
solver.fit(max_epochs=10000, callbacks=[monitor_callback])

# Obtain the solution
solution_neural_net_heat = solver.get_solution()

xs = np.linspace(0, L, 100)
ts = np.linspace(0, T, 100)
xx, tt = np.meshgrid(xs, ts)
sol_net = solution_neural_net_heat(xx, tt, to_numpy=True)

fig = figure(figsize=(6,6))
ax = fig.add_subplot(111, projection='3d')
ax.plot_surface(xx, tt, sol_net, cmap='magma')

```

Lampiran 1 3 Code metode Neural Network pada persamaan gelombang



UNIVERSITAS PGRI SEMARANG
FAKULTAS PENDIDIKAN MIPA DAN TEKNOLOGI INFORMASI
 PROGDI - PENDIDIKAN MATEMATIKA, BIOLOGI, FISIKA DAN TEKNOLOGI INFORMASI
 Jalan Lontar Nomor 1 (Sidodadi Timur) Telepon (024) 8316377 Fax. (024) 8448217 Semarang

USULAN TEMA SKRIPSI

Yth. Ketua Program Studi
 1. Pendidikan Matematika
 2. Pendidikan Biologi
 3. Pendidikan Fisika
 4. Pendidikan Teknologi Informasi

Dengan hormat,

Yang bertanda tangan dibawah ini,

Nama : FAKHA ARMAWANTO

NPM : 20230002

Program Studi/ Smt. : Pendidikan Fisika / semester 8

bermaksud mengajukan tema skripsi dengan judul:

PERSAMAPAN GELOMBANG SATU DIMENSI MENGGUNAKAN METODE FINITE
DIFFERENCE EXPLICIT DAN NEURAL NETWORK

Semarang, 19 September 2023

Yang mengajukan,

FAKHA ARMAWANTO
20230002

Menyetujui,

Pembimbing I

Wawan Kurniawan, S.Si, M.Si
NIDN 0629118101

Pembimbing II


Joto Setiawan, S.Si, M.Sc
NIDN 0620078101



UNIVERSITAS PGRI SEMARANG
FAKULTAS PENDIDIKAN MIPA DAN TEKNOLOGI INFORMASI
 Kampus: Jl. Dr. Cipto - Sidodadi Timur No. 24 Semarang Indonesia
 Telp. (024)8316377 Faks (024)8448217 Email: upgrismg@gmail.com Homepage: www.upgris.ac.id

LEMBAR PEMBIMBINGAN SKRIPSI

Nama Mahasiswa : Fardika Armawanto
 NPM : 20330002
 Prodi : Pendidikan Fisika
 Judul Skripsi : PERSAMAAN GELOMBANG SATU DIMENSI MENGGUNAKAN METODE FINITE DIFFERENCE EXPLICIT DAN NEURAL NETWORK
 Dosen Pembimbing I : Wawan Kurniawan, S.Si., M.Si
 Dosen Pembimbing II : Joko Saefan S.Si., M.Sc

No.	Hari, Tanggal	Uraian Bimbingan	Paraf
1.	Rabu, 13/09/2023	Pengajuan Judul	
2.	Kamis, 21/09/2023	Bimbingan Proposal	
3.	Kamis, 5/10/2023	Bimbingan Proposal	
4.	Senin, 23/10/2023	Revisi proposal	
5.	Kamis, 26/10/2023	Revisi proposal	
6.	Senin, 29/01/2024	Bimbingan BAB 3.	
7.	Selasa, 6/02/2024	Bimbingan BAB 4.	
8.	Rabu, 21/02/2024	Bimbingan BAB 5	
9.	Kedu, 28/02/2024	Bimbingan lengkap skripsi	
10.	Senin, 4/03/2024	Revisi Skripsi lengkap	
11.	Kamis, 14/03/2024	Bimbingan Skripsi Full	
12.	Senin, 18/03/2024	Acc Ujian.	

Dosen Pembimbing I,



Wawan Kurniawan, S.Si., M.Si
 NIDN 0629118101

Mahasiswa,



Fardika Armawanto
 NPM 20330002



UNIVERSITAS PGRI SEMARANG
FAKULTAS PENDIDIKAN MIPA DAN TEKNOLOGI INFORMASI
 Kampus: Jl. Dr.Cipto – Sidodadi Timur No. 24 Semarang Indonesia
 Telp. (024)8316377 Faks.(024)8448217 Email:upgrisng@gmail.com Homepage: www.upgris.ac.id

LEMBAR PEMBIMBINGAN SKRIPSI

Nama Mahasiswa : Fardika Armawanto
 NPM : 20330002
 Prodi : Pendidikan Fisika
 Judul Skripsi : PERSAMAAN GELOMBANG SATU DIMENSI MENGGUNAKAN METODE FINITE DIFFERENCE EXPLICIT DAN NEURAL NETWORK
 Dosen Pembimbing I : Wawan Kurniawan, S.Si., M.Si
 Dosen Pembimbing II : Joko Saefan S.Si., M.Sc

No.	Hari, Tanggal	Uraian Bimbingan	Paraf
1.	Kamis, 19/09/2023	Pengayaman judul	Sis Sis
2.	Jumat, 22/09/2023	Bimbingan proposal	Sis
3.	Senin, 01/10/2023	Bimbingan proposal	Sis
4.	Rabu, 25/10/2023	Rewisi proposal	Sis Sis
5.	Jumat, 27/10/2023	Rewisi proposal	Sis Sis
6.	Selasa, 30/01/2024	Bimbingan BAB 3	Sis
7.	Rabu, 7/02/2024	Bimbingan BAB 4	Sis
8.	Kamis, 22/02/2024	Bimbingan BAB 5	Sis
9.	Kamis, 29/02/2024	Bimbingan lengkap Skripsi	Sis
10.	Senin, 4/03/2024	Rewisi Skripsi lengkap	Sis
11.	Kamis, 14/03/2024	Bimbingan Skripsi Full	Sis
12.	Selasa, 19/03/2024	ACC Ujian	Sis

Dosen Pembimbing II,

Joko Saefan S.Si., M.Sc
 NIDN 0620078101

Mahasiswa,

Fardika Armawanto
 NPM 20330002