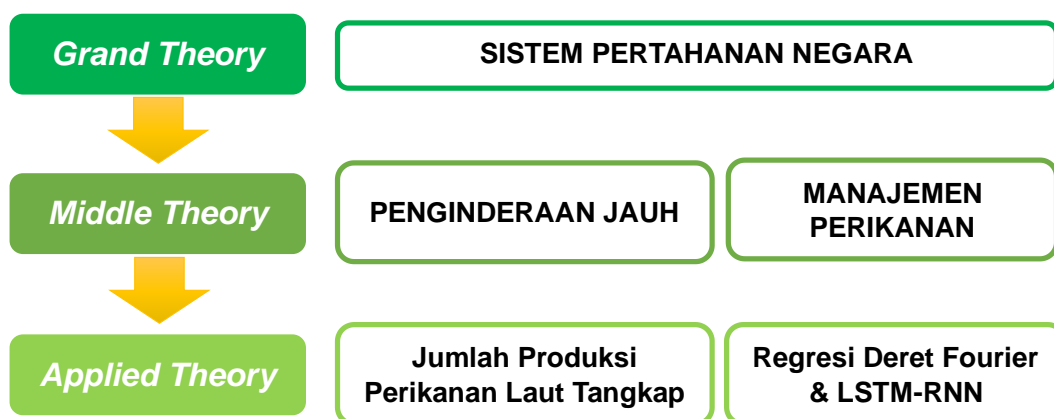


BAB 2 TINJAUAN PUSTAKA

2.1 Landasan Teori

Pada Penelitian ini, akan diuraikan landasan teori yang menjadi dasar untuk memahami dan menganalisis topik yang sedang diteliti. Landasan teori ini akan memberikan pemahaman yang mendalam tentang konsep-konsep kunci, kerangka kerja, dan prinsip-prinsip yang relevan yang terkait dengan subjek Penelitian. Melalui penggunaan landasan teori ini, diharapkan dapat memperluas pemahaman tentang topik Penelitian, memberikan konteks yang diperlukan, serta membangun fondasi yang kuat untuk Penelitian secara keseluruhan. Dengan demikian, dalam bab ini akan membahas secara rinci landasan teori yang digunakan sebagai pijakan intelektual untuk Penelitian ini.



Gambar 2. 1 Tingkatan Teori yang Digunakan

Sumber: Peneliti (2023)

2.1.1. Sistem Pertahanan Negara

Sistem pertahanan negara adalah sebuah konsep yang meliputi berbagai aspek, mulai dari doktrin militer, struktur organisasi, hingga teknologi pertahanan, yang semuanya bekerja bersama untuk melindungi kepentingan dan kedaulatan sebuah negara (Antari & Karpika, 2023). Sistem ini umumnya didesain untuk menghadapi ancaman eksternal,

seperti agresi militer dari negara lain, tetapi juga sering melibatkan elemen untuk mengatasi ancaman internal, seperti terorisme atau pemberontakan.

Pada dasarnya, sistem pertahanan negara dapat dibagi menjadi beberapa komponen utama. Pertama adalah angkatan bersenjata, yang biasanya terdiri dari angkatan darat, angkatan laut, dan angkatan udara. Masing-masing angkatan ini memiliki peran spesifik dalam pertahanan negara, dengan angkatan darat fokus pada operasi darat, angkatan laut bertanggung jawab untuk mengamankan perairan negara, dan angkatan udara bertugas melindungi wilayah udara dan memberikan dukungan kepada angkatan darat dan angkatan laut (Wibowo & Juwono, 2023). Selain itu, ada juga pasukan khusus yang dilatih untuk operasi khusus, termasuk operasi anti-terorisme dan penyelamatan sandera.

Komponen kedua adalah doktrin militer dan strategi pertahanan. Doktrin ini mencakup prinsip-prinsip dasar tentang bagaimana angkatan bersenjata harus beroperasi dalam konflik, sementara strategi pertahanan menentukan bagaimana sumber daya militer dan sipil digunakan untuk memenuhi tujuan-tujuan strategis negara (Frederick & Chandler, 2020). Ini termasuk penentuan prioritas dalam alokasi sumber daya, pengembangan kemampuan militer, dan perencanaan untuk berbagai skenario konflik.

Teknologi pertahanan adalah komponen ketiga yang penting. Ini melibatkan pengembangan dan akuisisi teknologi militer canggih, seperti pesawat tempur, kapal perang, sistem pertahanan rudal, dan sistem komunikasi dan pengawasan. Kemajuan teknologi telah menjadi faktor kunci dalam menentukan keefektifan sistem pertahanan, dengan negara-negara berusaha untuk memperbarui dan meningkatkan kemampuan mereka untuk menghadapi ancaman yang terus berkembang (Irfan et al., 2023).

Selain ketiga komponen tersebut, sistem pertahanan negara juga melibatkan kerjasama dengan negara lain melalui aliansi dan pakta pertahanan. Aliansi seperti NATO atau pakta pertahanan regional memungkinkan negara-negara anggota untuk bekerja sama dalam hal

pertahanan, berbagi sumber daya dan informasi intelijen, serta mengkoordinasikan strategi militer.

Pengelolaan sumber daya manusia dan logistik juga menjadi bagian penting dari sistem pertahanan. Ini termasuk pelatihan dan pendidikan personel militer, pengembangan kepemimpinan, serta penyediaan dan distribusi peralatan dan persediaan yang diperlukan untuk operasi militer. Manajemen logistik yang efisien krusial untuk memastikan bahwa pasukan dapat dioperasikan secara efektif dan efisien, terutama selama konflik (Petreski et al., 2016).

Peran masyarakat sipil dan industri dalam sistem pertahanan juga tidak boleh diabaikan. Dalam banyak negara, industri pertahanan memainkan peran kunci dalam mendukung upaya pertahanan melalui pengembangan dan produksi peralatan militer (Kinne & Kang, 2023). Selain itu, dukungan masyarakat terhadap kebijakan pertahanan dan angkatan bersenjata juga penting untuk memastikan kohesi dan efektivitas sistem pertahanan secara keseluruhan. Sistem pertahanan negara adalah sebuah sistem kompleks yang memerlukan koordinasi dan integrasi dari berbagai elemen, mulai dari kekuatan militer hingga dukungan teknologi dan masyarakat. Melalui sistem ini, sebuah negara mampu untuk melindungi kedaulatan dan kepentingannya dari ancaman eksternal maupun internal.

2.1.2. Manajemen Perikanan

Manajemen pengelolaan perikanan adalah suatu pendekatan terstruktur yang bertujuan untuk mengoptimalkan pemanfaatan sumber daya perikanan dengan cara yang berkelanjutan (Yanti et al., 2021). Ini melibatkan serangkaian kegiatan yang dirancang untuk memonitor, menilai, dan mengatur kegiatan perikanan agar tetap dalam batas yang dapat diterima dari segi ekologi, ekonomi, dan sosial. Salah satu aspek kunci dalam manajemen perikanan adalah penilaian stok ikan. Ini melibatkan pemantauan populasi ikan dan habitatnya untuk memastikan bahwa kegiatan penangkapan tidak melebihi kapasitas regenerasi sumber daya

tersebut (Nasution & Sunarno, 2017). Dengan memahami seberapa banyak ikan yang dapat ditangkap tanpa mengancam kelangsungan populasi, pengelola dapat menetapkan kuota penangkapan yang sesuai untuk mencegah *overfishing* atau penangkapan berlebih.



Gambar 2. 2 Penerapan Kebijakan Penangkapan Terukur di WPP 715 (Sebagian) dan 718

Sumber: Direktur Jenderal Perikanan Tangkap (2021)

Selain itu, manajemen pengelolaan perikanan juga mempertimbangkan dampak lingkungan dari kegiatan perikanan. Ini mencakup pemantauan dan pengendalian dampak terhadap ekosistem perairan, seperti kerusakan habitat, pencemaran, dan interaksi dengan spesies lain. Upaya-upaya seperti pembatasan alat tangkap tertentu, penetapan zona perlindungan perikanan, dan program restorasi habitat seringkali menjadi bagian dari strategi pengelolaan. Aspek sosial dan ekonomi juga menjadi pertimbangan penting dalam manajemen perikanan (Rahel, 2016). Tujuannya adalah untuk memastikan bahwa kegiatan perikanan memberikan manfaat ekonomi bagi masyarakat, sekaligus mempertahankan keadilan dan akses bagi nelayan kecil. Hal ini dapat melibatkan kebijakan seperti sistem lisensi, hak penangkapan, atau program pelatihan untuk meningkatkan keterampilan dan kapasitas nelayan.

Teknologi dan inovasi juga memainkan peran penting dalam manajemen perikanan modern. Sistem pemantauan satelit, aplikasi *mobile* untuk pelaporan tangkapan, dan teknologi lainnya membantu meningkatkan efisiensi dan akurasi dalam pengumpulan data, yang pada realitanya memungkinkan pengambilan keputusan yang lebih tepat (Tangke, 2010). Manajemen pengelolaan perikanan yang efektif memerlukan kerjasama antara berbagai pemangku kepentingan, termasuk pemerintah, industri perikanan, komunitas nelayan, organisasi non-pemerintah, dan masyarakat (Haas et al., 2021). Kolaborasi ini penting untuk memastikan bahwa kebijakan dan tindakan yang diambil mencerminkan kebutuhan dan aspirasi dari semua pihak yang terlibat.

Pengetahuan dan kesadaran masyarakat juga menjadi komponen krusial dalam manajemen perikanan. Masyarakat yang terinformasi dan sadar akan pentingnya keberlanjutan perikanan lebih cenderung mendukung dan mematuhi regulasi dan kebijakan yang ada (Nasution et al., 1992). Oleh karena itu, kampanye kesadaran, pelatihan, dan program edukasi seringkali menjadi bagian integral dari strategi pengelolaan. Selain itu, adaptasi dan fleksibilitas adalah kunci dalam menghadapi tantangan yang terus berubah dalam sektor perikanan. Dengan perubahan iklim, pergeseran pola migrasi ikan, dan dinamika pasar global, kebutuhan untuk meninjau ulang dan menyesuaikan pendekatan manajemen menjadi semakin penting (Fulton, 2021). Hal tersebut memerlukan sistem pemantauan yang kuat dan kemampuan untuk merespons dengan cepat terhadap perubahan yang terjadi.

Pengawasan dan penegakan hukum juga menjadi aspek penting dalam manajemen perikanan. Tanpa mekanisme yang efektif untuk memastikan kepatuhan terhadap regulasi, keberlanjutan sumber daya perikanan dapat terancam (Khan et al., 2016). Oleh karena itu, pemerintah dan organisasi terkait harus memiliki kapasitas dan sumber daya yang cukup untuk mengawasi aktivitas perikanan dan mengambil tindakan ketika ditemukan pelanggaran. Penelitian dan pengembangan terus-menerus

diperlukan untuk meningkatkan praktik-praktik perikanan yang berkelanjutan (Amura & Pirhel, 2021). Melalui Penelitian, akan dapat memahami lebih baik tentang ekologi perikanan, teknologi penangkapan yang ramah lingkungan, dan metode pengelolaan yang lebih efektif. Dengan demikian, manajemen pengelolaan perikanan bukanlah suatu tugas yang statis, tetapi suatu proses dinamis yang memerlukan komitmen, kolaborasi, dan inovasi dari semua pihak yang terlibat.

2.1.3. Penginderaan Jauh

Penginderaan jauh merupakan sebuah teknologi yang digunakan untuk mengumpulkan informasi tentang bumi dan objek di permukaannya tanpa harus secara fisik berada di lokasi tersebut (Campbell & Wynne, 2011). Metode ini memanfaatkan sensor-sensor yang terpasang pada satelit, pesawat udara, atau bahkan *drone*, yang dapat mengambil data melalui pemantauan elektromagnetik atau gelombang energi lainnya. Teknologi penginderaan jauh memainkan peran penting dalam berbagai bidang, termasuk pengelolaan sumber daya alam, pemantauan lingkungan, pemetaan permukaan bumi, dan pemantauan cuaca. Salah satu kelebihan utama penginderaan jauh adalah kemampuannya untuk mencakup area yang luas dengan cepat dan efisien. Dengan menggunakan satelit atau pesawat udara, kita dapat mengambil gambar atau data dari daerah yang sulit dijangkau secara manual, seperti daerah terpencil atau wilayah yang berbahaya (Zhang et al., 2021).

Penginderaan jauh juga memungkinkan kita untuk mengamati perubahan yang terjadi pada bumi dari waktu ke waktu. Dengan menggunakan citra atau data yang diambil secara berkala, dapat melacak pola perubahan seperti deforestasi, pola cuaca, atau perubahan permukaan lahan (Migliaccio et al., 2022). Informasi ini sangat berharga dalam menginformasikan keputusan yang berkaitan dengan pengelolaan sumber daya alam, mitigasi bencana alam, atau perencanaan perkotaan. Salah satu aspek kunci dari penginderaan jauh adalah analisis citra atau

data yang dikumpulkan. Dengan menggunakan teknik pemrosesan gambar dan pengolahan data, kita dapat mengidentifikasi objek atau fitur tertentu dalam citra, seperti hutan, sungai, atau bahkan bangunan. Analisis ini dapat memberikan pemahaman tentang kondisi lingkungan dan membantu dalam pengambilan keputusan yang berhubungan dengan berbagai sektor.

Dalam beberapa tahun terakhir, penginderaan jauh juga telah dikombinasikan dengan teknologi lain seperti *Artificial Intelligence* (AI) untuk meningkatkan kemampuannya. AI dapat membantu dalam pengenalan pola, klasifikasi objek, dan bahkan dalam menganalisis data yang kompleks. Hal ini membuka peluang baru dalam penggunaan penginderaan jauh untuk berbagai aplikasi, termasuk pemantauan bencana alam secara *real-time*, pemetaan urbanisasi, dan pemantauan perubahan iklim.

Sistem Informasi Geografi (SIG) adalah *platform* berbasis komputer, yang berfungsi untuk menyimpan, mengatur, menganalisis, dan mengembalikan data dengan referensi spasial untuk keperluan terkait pemetaan dan perencanaan. Kombinasi teknologi penginderaan jauh dan SIG meningkatkan efektivitas pengumpulan data dan presisi hasil pemetaan yang digunakan dalam perencanaan dan manajemen wilayah. Teknologi penginderaan jauh menawarkan kelebihan dibandingkan dengan fotografi udara, termasuk dari aspek biaya, frekuensi pengambilan gambar area yang sama, kemampuan memilih panjang gelombang untuk mengatasi gangguan atmosfer, dan kemampuan menyesuaikan band spektral sesuai kebutuhan (Lu et al., 2023). Kehadiran penginderaan jauh dan SIG telah memperkuat posisi geografi dalam mengatasi isu-isu ruang, lingkungan, dan wilayah serta berkontribusi pada penyediaan data spasial untuk pembuatan kebijakan.

NASA Earth Observing System telah menciptakan Satelit Terra dan Aqua. Dalam proses tersebut, mereka berkolaborasi dengan Kementerian Perdagangan dan Industri Jepang (MITI). Ada empat sistem sensor yang terintegrasi dalam Satelit Terra, yaitu:

- a. ASTER (*Advanced Spaceborne Thermal Emission and Reflection Radiometer*) yang merupakan kreasi dari Jepang.

Sementara dari Amerika Serikat, ada:

- b. MODIS
- c. CERES
- d. MISR

Satelit Aqua dikenal sebagai "kembaran" dari Satelit Terra, namun tanpa sensor ASTER. Terra melewati ekuator pada jam 10.30 pagi dan memiliki tujuan untuk mengambil gambar bumi di siang hari. Sementara itu, Aqua melewati ekuator pada jam 13.30 siang dan bertujuan untuk mendapatkan data permukaan bumi di malam hari. Kedua satelit tersebut mengorbit dengan sinkronisasi terhadap matahari (Danoedoro, P 2012, 84).

2.1.4. Pemetaan Zona Potensi Penangkapan Ikan (ZPPI)

Pemetaan zona potensi penangkapan ikan adalah proses identifikasi dan penentuan area di perairan laut yang memiliki potensi tinggi untuk menangkap ikan secara efektif. Pemetaan ini dilakukan dengan menggunakan berbagai data dan informasi, termasuk data cuaca, suhu air, kedalaman laut, kondisi oseanografi, dan pola migrasi ikan. Tujuan utama dari pemetaan zona potensi penangkapan ikan adalah untuk membantu nelayan dalam mengoptimalkan hasil tangkapan mereka dan mengurangi waktu serta biaya yang diperlukan dalam mencari ikan (Daqamseh et al., 2019). Proses pemetaan zona potensi penangkapan ikan melibatkan pengumpulan data dari berbagai sumber, seperti penginderaan jauh melalui satelit, pengamatan lapangan, dan informasi dari nelayan yang berpengalaman. Data ini kemudian dianalisis dan diproses menggunakan teknik pemodelan dan sistem informasi geografis untuk menghasilkan peta zona potensi penangkapan ikan. Peta tersebut menunjukkan area-area di laut yang memiliki kemungkinan tinggi untuk menemukan konsentrasi ikan yang lebih besar (Bean et al., 2017).


Dalam pemetaan zona potensi penangkapan ikan, faktor-faktor penting seperti suhu air, Tinggi Gelombang Air Laut, dan ketersediaan makanan menjadi pertimbangan utama. Misalnya, beberapa jenis ikan cenderung berkumpul di area dengan suhu air tertentu atau mengikuti aliran arus laut yang membawa nutrisi yang cukup. Selain itu, pemetaan juga memperhatikan faktor topografi dasar laut, seperti kontur dasar laut dan struktur bawah air seperti terumbu karang atau batuan, yang menjadi habitat ikan tertentu. Pemetaan ZPPI memberikan manfaat besar bagi nelayan. Dengan mengetahui lokasi-lokasi yang memiliki potensi tinggi untuk menangkap ikan, nelayan dapat mengarahkan usaha penangkapan mereka dengan lebih efisien. Mereka dapat menghemat waktu dan bahan bakar yang sebelumnya terbuang karena mencari ikan di area yang tidak produktif. Selain itu, pemetaan juga membantu dalam pengelolaan perikanan yang berkelanjutan dengan meminimalkan penangkapan berlebihan di area yang rawan *overfishing* dan menjaga keseimbangan ekosistem laut.

Dalam era teknologi informasi dan komunikasi yang semakin maju, pemetaan ZPPI juga dapat dilakukan secara *real-time*. Nelayan dapat memanfaatkan informasi dan perkiraan terkini tentang kondisi perairan laut melalui aplikasi dan sistem pemberitahuan. Dengan demikian, mereka dapat mengakses data terbaru dan membuat keputusan yang lebih baik dalam menentukan zona penangkapan ikan yang optimal. Pemetaan zona potensi penangkapan ikan adalah alat penting dalam industri perikanan. Dengan memanfaatkan informasi dan teknologi yang tepat, nelayan dapat meningkatkan efisiensi penangkapan mereka, mengurangi dampak lingkungan, dan mendukung pengelolaan perikanan yang berkelanjutan.

2.1.5. Regresi Nonparametrik

Pada pendekatan regresi parametrik bentuk fungsi regresi diasumsikan mempunyai bentuk tertentu seperti linear, kuadratik, eksponensial, dll. Dalam estimasi ini, fokusnya ada pada menghitung

sejumlah parameter yang terlibat. Namun, dalam pendekatan regresi nonparametrik, tidak ada asumsi khusus tentang bentuk fungsi regresi. Fungsi regresi nonparametrik hanya diasumsikan sebagai fungsi yang halus atau terdefinisi dalam suatu ruang fungsi tertentu. Ini memberikan kebebasan yang besar dalam menentukan bentuk fungsi regresi (Eubank, 1998). Ada berbagai metode *smoothing* yang digunakan dalam regresi nonparametrik, termasuk penggunaan kernel, lokal linear, *spline least square*, *penalized spline*, dan deret Fourier. Berikut adalah contoh data yang tidak mengikuti pola yang konsisten, sehingga lebih sesuai untuk menggunakan metode regresi nonparametrik.



Gambar 2. 3 Scatterplot Data

Chamidah (2020) menyatakan Data pengamatan (X_i, Y_i) dapat dinyatakan dalam model regresi nonparametrik dengan persamaan sebagai berikut:

$$Y_i = m(X_i) + \varepsilon_i \quad (2.1)$$

Dengan $m(X_i)$ adalah fungsi regresi yang diasumsikan *smooth* yaitu fungsi yang kontinu dan diferensiabel sedangkan ε_i merupakan *error* random dengan nilai mean adalah nol dan variansi σ^2 . Fungsi regresi $m(X_i)$ dapat diestimasi dengan teknik *smoothing* diantaranya yaitu kernel,

lokal linear, *spline least square*, *penalized spline*, dan deret Fourier. Parameter penghalus berfungsi untuk mengontrol kemulusan kurva (fungsi) regresi. Masing-masing estimator di dalam regresi nonparametrik mempunyai parameter penghalus yang berbeda (Chamidah, 2020).

Agar mendapatkan hasil estimasi yang optimal yaitu tidak terlalu kasar atau tidak terlalu mulus diperlukan metode untuk memilih parameter penghalus. Metode yang dapat digunakan dalam pemilihan parameter penghalus adalah sebagai berikut:

- a. Metode *Cross Validation (CV)*

$$CV = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{m}_{h,-i}(X_i))^2 \quad (2.2)$$

$\hat{m}_{h,-i}(X_i)$ adalah estimasi pada titik X_i dengan mengeluarkan observasi ke- i

- b. Metode *Generalized Cross Validation (GCV)*

$$GCV = \frac{\sum_{i=1}^n (Y_i - \hat{m}(X_i))^2}{(n^{-1} \text{trace}[I - H(X)])^2} \quad (2.3)$$

2.1.6. Regresi Nonparametrik Deret Fourier

Joseph Fourier (1768-1830) mengembangkan Deret Fourier untuk menangani isu persamaan panas pada lempeng metalik. Dalam bidang matematika, Deret Fourier menggambarkan pemisahan fungsi periodik menjadi kombinasi dari fungsi yang berosilasi, seperti fungsi sinus, cosinus, atau eksponensial kompleks. Chamidah (2020) menyatakan bahwa Deret Fourier diartikan sebagai fungsi polinomial trigonometri dengan adaptabilitas yang luar biasa, karena mampu merepresentasikan kurva fungsi sinus dan cosinus.

Analisis regresi nonparametrik deret Fourier menjadi penting dalam pemodelan data *time series*, khususnya karena kelebihanannya dalam menangani data yang kompleks dan tidak memiliki pola tertentu (Suparti et al., 2018). Berikut ini adalah beberapa kelebihan utama dari metode ini:

1) Fleksibilitas dalam Memodelkan Hubungan

Salah satu kelebihan terbesar dari regresi nonparametrik, termasuk deret Fourier, adalah fleksibilitasnya dalam memodelkan hubungan antara variabel-variabel. Dalam data *time series*, pola atau tren seringkali sulit diprediksi dan tidak selalu mengikuti bentuk linier atau pola matematis sederhana. Regresi nonparametrik deret Fourier mampu menyesuaikan diri dengan struktur data ini, mengakomodasi fluktuasi dan non-linearitas yang mungkin tidak terdeteksi dengan metode parametrik.

2) Penanganan Musiman dan Siklikal

Data *time series* seringkali memiliki komponen musiman atau siklikal yang kuat. Analisis deret Fourier secara khusus dirancang untuk menangani fenomena periodik. Dengan menggunakan transformasi Fourier, maka dapat mengidentifikasi dan memodelkan komponen periodik dalam data, seperti tren tahunan atau bulanan, yang sangat berguna dalam banyak aplikasi praktis.

3) Pengurangan *Overfitting*

Dalam regresi nonparametrik, risiko *overfitting* (model terlalu pas dengan data sampel dan gagal untuk menggeneralisasi) seringkali lebih rendah dibandingkan dengan metode parametrik.

4) Penyesuaian terhadap Data yang Tidak Homogen

Data *time series* seringkali tidak homogen, berarti sifat statistik data berubah seiring waktu. Metode nonparametrik seperti regresi deret Fourier memungkinkan penyesuaian yang lebih baik terhadap perubahan ini, dibandingkan dengan metode parametrik yang mengasumsikan sifat statistik tetap.

5) Kemudahan Interpretasi

Meskipun regresi nonparametrik dapat lebih kompleks secara komputasi, hasilnya seringkali lebih mudah diinterpretasikan dalam konteks praktis. Misalnya, dalam analisis deret Fourier, dapat

dengan jelas melihat dan menafsirkan frekuensi dan amplitudo dari komponen periodik dalam data.

Namun, penting untuk diingat bahwa analisis regresi nonparametrik deret Fourier juga memiliki keterbatasan, seperti kebutuhan untuk sampel data yang cukup besar dan potensi kesulitan dalam pemilihan *bandwidth* yang tepat. Selain itu, meskipun metode ini fleksibel, akan tetapi tidak selalu memberikan prediksi yang paling akurat jika struktur sebenarnya dari data lebih cocok dengan model parametrik. Oleh karena itu, pemilihan metode harus disesuaikan dengan karakteristik data dan tujuan analisis.

2.1.6.1. Definisi Fungsi Periodik dan Deret Fourier

Fungsi $f(x)$ disebut sebagai periodik jika nilai dari fungsi itu muncul kembali pada jarak waktu tertentu. Jarak waktu antara setiap kemunculan kembali disebut sebagai periode osilasi, di mana osilasi mengacu pada fluktuasi berulang terkait waktu dari sebuah pengukuran. Menurut Damanik (2010) menyatakan bahwa suatu fungsi $f(x)$ dapat disebut mempunyai periode sebesar T atau periodik dengan periode $T > 0$ jika untuk semua x berlaku:

$$f(x+T) = f(x) \quad (2.4)$$

Berdasarkan persamaan (2.4) di atas, maka:

$$\begin{aligned} f(x+2T) &= f((x+T)+T) \\ &= f(x+T) \\ &= f(x) \end{aligned} \quad (2.5)$$

sehingga dapat disimpulkan bahwa $f(x+nT) = f(x)$.

Misalkan suatu fungsi $f(x)$ didefinisikan dalam selang $(-L, L)$ dan di luar selang ini oleh $f(x+2L) = f(x)$, sehingga $f(x)$ mempunyai periode $2L$. Setiap fungsi $f(x)$ yang periodik dapat dibuat deret Fourier, sebagai berikut:

$$f(x) = \frac{a_0}{2} + \sum_{n=1}^{\infty} \left(a_n \cos\left(\frac{n\pi x}{L}\right) + b_n \sin\left(\frac{n\pi x}{L}\right) \right) \quad (2.6)$$

dengan $a_0, a_n,$ dan b_n adalah koefisien-koefisien Fourier.

Nilai koefisien-koefisien Fourier itu dapat diperoleh dari persamaan berikut:

$$\begin{aligned} a_0 &= \frac{1}{L} \int_{-L}^L f(x) dx, \\ a_n &= \frac{1}{L} \int_{-L}^L f(x) \cos\left(\frac{n\pi x}{L}\right) dx, \\ b_n &= \frac{1}{L} \int_{-L}^L f(x) \sin\left(\frac{n\pi x}{L}\right) dx \end{aligned} \quad (2.7)$$

Apabila mengubah batas integral dengan membuat periode tetap $2L$, maka dapat menggunakan relasi berikut untuk menentukan koefisien-koefisien Fourier suatu fungsi periodik yang diekspansikan ke dalam deret Fourier, yaitu:

$$\begin{aligned} a_0 &= \frac{1}{L} \int_c^{c+2L} f(x) dx, \\ a_n &= \frac{1}{L} \int_c^{c+2L} f(x) \cos\left(\frac{n\pi x}{L}\right) dx, \\ b_n &= \frac{1}{L} \int_c^{c+2L} f(x) \sin\left(\frac{n\pi x}{L}\right) dx \end{aligned} \quad (2.8)$$

dengan c adalah sembarang bilangan real.

2.1.6.2. Fungsi Ganjil dan Fungsi Genap

Suatu fungsi dapat sebagai fungsi ganjil atau fungsi genap atau gabungan dari keduanya (Damanik, 2010). Suatu fungsi $f(x)$ disebut fungsi ganjil jika fungsi tersebut memenuhi sifat:

$$f(-x) = -f(x)$$

dan disebut fungsi genap jika fungsi itu memenuhi sifat:

$$f(-x) = f(x)$$

Untuk menentukan koefisien-koefisien Fourier $a_0, a_n,$ dan b_n dari fungsi periodik fungsi genap dan ganjil dengan $L = \frac{1}{2}T = \frac{1}{2}$ periode digunakan perumusan sebagai berikut:

Jika $f(x)$ genap maka:

$$\begin{aligned} a_0 &= \frac{2}{L} \int_0^L f(x) dx \\ a_n &= \frac{2}{L} \int_0^L f(x) \cos \frac{n\pi x}{L} dx \\ b_n &= 0 \end{aligned} \quad (2.9)$$

Untuk kasus ini, dikatakan $f(x)$ fungsi genap dan teruraikan dalam deret cosinus ($b_n = 0$). Grafik fungsi genap simetris terhadap sumbu Y.

Jika $f(x)$ ganjil maka:

$$\begin{aligned} a_0 &= 0 \\ a_n &= 0 \\ b_n &= \frac{2}{L} \int_0^L f(x) \sin \frac{n\pi x}{L} dx \end{aligned} \quad (2.10)$$

Untuk kasus ini, dikatakan $f(x)$ fungsi ganjil dan teruraikan dalam deret sinus ($a_n = 0$). Grafik fungsi ganjil simetris terhadap titik asal.

Menurut Damanik (2010), dalam konteks deret Fourier, ketika berbicara tentang fungsi yang memiliki sifat ganjil, maka hanya akan ada unsur-unsur sinus yang terlibat. Hal lain, jika membahas deret Fourier yang terkait dengan fungsi genap, maka hanya akan terdapat unsur-unsur cosinus atau elemen konstan yang dapat dianggap sebagai suku cosinus. Hal ini sebagai konsekuensi dari sifat fungsi ganjil dan fungsi genap terhadap integrasi.

Berdasarkan sifat fungsi genap dan fungsi ganjil dapat diketahui bahwa ekspansi suatu fungsi ganjil ke dalam deret Fourier hanya menghasilkan koefisien-koefisien yang bersesuaian dengan suku yang mengandung sinus ($a_n = 0, b_n \neq 0$). Sementara itu, untuk fungsi genap jika

diekspansikan ke dalam deret Fourier, maka hanya mengandung suku-suku cosinus atau suatu konstanta yang dapat dipandang sebagai cosinus (sebab $a_n \neq 0$, $b_n = 0$). Untuk mendapatkan suatu fungsi genap atau fungsi ganjil saja dari suatu fungsi $f(x)$ yang diberikan, maka perlu memperluas selangnya (intervalnya) terlebih dahulu agar diperoleh fungsi genap atau ganjil.

2.1.7. **Recurrent Neural Network (RNN)**

Recurrent Neural Network (RNN) adalah salah satu jenis arsitektur jaringan saraf tiruan yang dirancang khusus untuk memproses data berurutan, seperti teks, audio, dan deret waktu. RNN memiliki kemampuan untuk mengatasi masalah ketergantungan temporal dalam data, yang membuatnya sangat berguna dalam tugas-tugas yang melibatkan pemahaman urutan atau pola dalam data tersebut (Sang et al., 2021).

Struktur dasar dari RNN melibatkan unit atau "sel" yang diulang sepanjang urutan data. Setiap sel menerima dua jenis *input*: *input* saat ini dari data urutan yang sedang diproses dan *output* dari sel sebelumnya dalam urutan (jika ada). *Input* saat ini dan *output* sebelumnya digunakan untuk menghasilkan *output* sel saat ini dan juga disimpan dalam memori sel untuk digunakan dalam langkah berikutnya.

RNN memiliki fleksibilitas dalam mengadaptasi panjang urutan data yang berbeda. Ini berarti mereka dapat digunakan untuk memodelkan ketergantungan temporal jangka pendek maupun jangka panjang dalam data. Dengan demikian, RNN dapat digunakan dalam berbagai tugas seperti pemodelan bahasa alami (NLP), pengenalan suara, dan prediksi deret waktu (Shen et al., 2020).

Namun, RNN juga memiliki beberapa tantangan. Salah satu masalah utama adalah masalah *vanishing gradient*, di mana gradien yang diteruskan ke belakang dalam proses pelatihan menjadi sangat kecil, menyebabkan kesulitan dalam pembelajaran jangka panjang. Ini dapat membatasi kemampuan RNN untuk mengingat informasi dalam urutan data

yang sangat panjang. Selain itu, RNN cenderung menghitung langkah demi langkah dalam urutan data, yang bisa membuatnya kurang efisien secara komputasi.

Untuk mengatasi beberapa masalah ini, variasi RNN seperti *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) telah dikembangkan. Mereka memiliki mekanisme khusus yang membantu mengatasi masalah *vanishing gradient* dan beberapa tantangan lainnya, menjadikannya pilihan yang lebih baik dalam banyak kasus penggunaan praktis.


$$S_t = f((U \cdot X_t) + (W \cdot S_{t-1})) \quad (2.11)$$

$$O_t = g(V \cdot S_t) \quad (2.12)$$

Keterangan:

- S : memori jaringan pada waktu ke- t
- U , V , dan W : matriks bobot berbagi di setiap layer
- X_t dan O_t : mewakili input dan output pada waktu ke- t
- $F(\dots)$ dan $g(\dots)$: mewakili fungsi nonlinear

RNN memiliki struktur yang meliputi lapisan *input*, lapisan tersembunyi, dan lapisan *output*. Biasanya, model RNN mengandung aliran informasi searah dari lapisan input ke lapisan tersembunyi, serta sintesis aliran informasi searah dari lapisan tersembunyi waktu sebelumnya ke lapisan tersembunyi saat ini (Chen, 2021). Lapisan tersembunyi dapat dianggap sebagai inti dari seluruh jaringan yang mengarahkan informasi dari satu ujung ke ujung yang lain. Dalam hal ini, arsitektur model RNN terlihat seperti berikut:




Gambar 2. 4 Model Arsitektur RNN

RNN memiliki kemampuan untuk memanfaatkan memori dalam memproses urutan masukan. Lapisan tersembunyi mengumpulkan informasi pada titik waktu sebelumnya, sedangkan keluaran berasal dari waktu saat ini serta memori yang ada sebelumnya (Dangovski et al., 2019). RNN beroperasi dengan cara yang ketika keluaran menjadi semakin berdekatan dengan *input*, terkait dengan informasi dari simpul sebelumnya, lalu informasi tersebut diteruskan ke simpul berikutnya.

2.1.8. Long Short-Term Memory (LSTM)

Long Short-Term Memory Recurrent Neural Network (LSTM RNN) adalah salah satu perkembangan dari jaringan saraf yang mampu memahami ketergantungan jangka panjang. Pada tahun 1997, Hochreiter dan Schmidhuber memperkenalkan LSTM-RNN, yang kemudian mengalami perbaikan dan menjadi sangat populer. LSTM-RNN sangat efektif dalam menyelesaikan berbagai jenis masalah. Terdapat beberapa jenis unit LSTM yang berbeda. Struktur umumnya melibatkan *forget gate*, gerbang input (*input gate*), dan gerbang keluaran (*output gate*). Berikut ini contoh struktur LSTM-RNN.



Gambar 2. 5 Arsitektur LSTM-RNN

Tiap unit dalam jaringan LSTM-RNN menyimpan informasi atau status sel (*cell state*) untuk durasi yang bisa pendek atau panjang. *Gate* input mengendalikan seberapa jauh informasi baru diizinkan masuk ke dalam unit sel tersebut, *gate* penghapusan mengelola sejauh mana

informasi tetap dipertahankan dalam sel, dan *gate* keluaran mengatur sejauh mana informasi dalam sel digunakan untuk menghasilkan keluaran dari unit LSTM-RNN. Koneksi berulang ada di antara ketiga *gate* ini. Setiap gerbang memiliki parameter sendiri, termasuk bobot dan pergeseran (bias).

Long Short-Term Memory (LSTM) merupakan varian dari *Recurrent Neural Networks* (RNN) yang dirancang khusus untuk mengatasi masalah yang terkait dengan dependensi jangka panjang dalam data urutan, seperti dalam data *time series*. Berikut adalah beberapa kelebihan LSTM-RNN dalam penerapan pada data *time series*.

1) Mengatasi Masalah *Vanishing Gradient*

Salah satu keunggulan utama LSTM adalah kemampuannya untuk mengatasi masalah *vanishing gradient* yang sering dihadapi oleh RNN tradisional. Dalam RNN standar, ketika jaringan belajar melalui proses *backpropagation*, gradien dapat menjadi sangat kecil sehingga pembelajaran menjadi sangat lambat atau berhenti. LSTM mengatasi ini dengan menggunakan mekanisme gerbang (*gate*) yang memungkinkan informasi untuk bergerak melalui unit selama interval waktu yang lebih lama (Rosca & Deisenroth, 2023).

2) Memori Jangka Panjang dan Pendek

LSTM memiliki kemampuan untuk menyimpan informasi untuk jangka waktu yang panjang dan pendek. Ini sangat penting dalam data *time series* di mana ketergantungan bisa terjadi pada interval waktu yang berbeda. Struktur LSTM dengan *input gate*, *forget gate*, dan *output gate* memungkinkan jaringan untuk memilih informasi mana yang harus diingat atau dilupakan.

3) Fleksibilitas dalam Menangkap Ketergantungan Temporal

Dalam data *time series*, hubungan antar titik data sangat kompleks. LSTM mampu belajar ketergantungan ini dengan lebih efektif dibandingkan dengan RNN tradisional. LSTM dapat belajar dari urutan data dengan ketergantungan jarak jauh, yang sangat berguna dalam banyak aplikasi *time series* seperti prediksi cuaca, analisis

keuangan, prediksi produksi perikanan, pemantauan Kesehatan, dan sebagainya.

4) Lebih Efisien dalam Pemodelan Urutan Data

LSTM dirancang untuk bekerja dengan urutan data, yang membuatnya sangat cocok untuk data *time series*. LSTM mampu mengolah dan membuat prediksi berdasarkan urutan data historis, yang memberikan konteks yang lebih baik untuk pemodelan dan prediksi.

5) Kemampuan Generalisasi yang Lebih Baik

LSTM cenderung memiliki kemampuan generalisasi yang lebih baik dibandingkan dengan RNN tradisional. Ini berarti lebih efektif dalam menghindari *overfitting*, terutama pada dataset yang besar dan kompleks.

6) Penerapan dalam Berbagai Bidang

LSTM telah berhasil diterapkan dalam berbagai bidang yang memerlukan analisis data *time series*, termasuk keuangan, cuaca, kesehatan, dan banyak lagi. Hal ini menunjukkan fleksibilitas dan efektivitasnya dalam berbagai jenis data dan aplikasi.

LSTM-RNN menawarkan solusi yang lebih *robust* dan efektif dalam mengatasi tantangan yang terkait dengan data *time series*, terutama terkait dengan dependensi jangka panjang dan kompleksitas dalam data urutan. Penggunaan gerbang dan memori internal memungkinkan LSTM untuk belajar dan mengingat informasi penting dari data urutan, menjadikannya pilihan yang sangat baik untuk banyak aplikasi *time series*.

2.1.9. Validasi Model

Proses validasi dijalankan untuk mengevaluasi kualitas model yang diterapkan dalam proses peramalan. Semakin rendah nilai *Mean Square Error* (MSE) dan *Root Mean Square Error* (RMSE), semakin baik performa model dalam peramalan (Gorguluarslan & Choi, 2016). *Mean Square Error* (MSE) dan *Root Mean Square Error* (RMSE) adalah metrik evaluasi yang

umum digunakan dalam statistika dan machine learning untuk mengukur sejauh mana perkiraan atau prediksi model statistika atau machine learning mendekati nilai sebenarnya. MSE adalah rata-rata dari kuadrat selisih antara nilai prediksi dan nilai sebenarnya. Semakin kecil nilai MSE, semakin baik model dalam membuat prediksi yang akurat. Namun, MSE tidak selalu mudah diinterpretasikan karena unitnya adalah kuadrat dari unit aslinya. Kemudian untuk RMSE adalah akar kuadrat dari MSE dan digunakan untuk memberikan ukuran kesalahan yang sebanding dengan skala aslinya. Karena RMSE dihitung dari MSE, nilai RMSE akan memiliki unit yang sama dengan nilai sebenarnya dan lebih mudah diinterpretasikan. Semakin kecil nilai RMSE, semakin baik performa model. Untuk menghitung MSE dan RMSE, dapat digunakan rumus berikut:

$$MSE = \frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n} \quad (2.13)$$

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}} \quad (2.14)$$

Keterangan:

- y_t : nilai pengamatan pada waktu ke- t
- \hat{y}_t : nilai dengan pada waktu ke- t
- t : $1, 2, 3, 4, \dots, n$
- n : banyaknya pengamatan

2.2 Hasil Penelitian Terdahulu

Pada bagian ini, akan disajikan hasil Penelitian terdahulu yang relevan dengan topik Penelitian. Melalui tinjauan literatur yang komprehensif, Peneliti telah mengumpulkan dan menganalisis beberapa Penelitian yang telah dilakukan sebelumnya yang berkaitan dengan subjek yang sama atau terkait dengan Penelitian ini. Hasil Penelitian terdahulu ini memberikan wawasan dan temuan yang berharga yang dapat membantu

memperdalam pemahaman tentang topik yang sedang diteliti, mengidentifikasi kesenjangan pengetahuan yang masih ada, serta merumuskan pertanyaan Penelitian yang relevan. Dalam bab ini, Peneliti akan menyajikan secara rinci hasil Penelitian terdahulu tersebut, membandingkan temuan-temuan yang ada, serta mengevaluasi kekuatan dan kelemahan masing-masing Penelitian.

Pertama, penelitian yang dilakukan oleh Eros Fikri Syahram, M. Machmud Effendy, dan Novendra Setyawan (2021) menguji efektivitas *Long Short-Term Memory Recurrent Neural Network* (LSTM-RNN) untuk peramalan posisi matahari. Hasil penelitian menunjukkan bahwa model data bulanan memiliki kesalahan terkecil (0,1%) dan efektif untuk prediksi sudut matahari, dengan potensi untuk mengoptimalkan tenaga surya. Perbedaan utama antara penelitian ini dengan penelitian terdahulu adalah fokus pada aplikasi metode regresi deret Fourier dan LSTM-RNN untuk memprediksi produksi perikanan laut tangkap di perairan Laut Arafura. Meskipun berbeda dalam konteks aplikasinya, kedua penelitian ini memiliki persamaan dalam penggunaan metode *Long Short-Term Memory Recurrent Neural Network* (LSTM-RNN) untuk meramalkan atau mengelola data.

Kedua, penelitian yang dilakukan oleh Anang Dwi Purwanto dan Dhia Puspa Ramadhani (2020) memiliki tujuan untuk menentukan distribusi suhu permukaan laut dan memetakan zona potensial penangkapan ikan di Laut Arafura. Hasilnya menunjukkan suhu permukaan laut relatif tinggi dan mengidentifikasi sekitar 70 zona penangkapan ikan potensial. Penelitian ini menyoroti peran penting citra satelit dalam pemetaan zona penangkapan ikan dan potensinya untuk meningkatkan tangkapan ikan di wilayah tersebut. Dalam penelitian yang akan dilakukan, peneliti akan memfokuskan pada perhitungan produksi perikanan laut tangkap di wilayah yang sama, Laut Arafura, dengan menggunakan analisis regresi deret Fourier dan *Long Short-Term Memory Recurrent Neural Network* (LSTM-RNN). Selain itu, pemetaan ZPPI akan dilakukan menggunakan citra

AQUA-MODIS, menambah dimensi analisis untuk pengelolaan wilayah perikanan laut tangkap di perairan Laut Arafura. Meskipun penelitian ini memiliki perbedaan dalam metode analisis dan sumber data, persamaannya terletak pada fokus keduanya dalam mengkaji potensi perikanan di wilayah yang sama, menunjukkan kontinuitas dalam pendekatan ilmiah untuk menganalisis dan mengelola sumber daya perikanan di Laut Arafura.

Ketiga, Penelitian sebelumnya yang dilakukan oleh Akhdan Aziz Khozi, Ayu Aprianti, Ahmad Dzaki Putra Dimas, Rifky Fauzi (2022) menunjukkan bahwa model *Recurrent Neural Network* (RNN) efektif dalam memprediksi kasus Covid-19 di Lampung, Indonesia, dengan akurasi tinggi dan kesalahan pemodelan rendah, menghasilkan RMSE 0,001 untuk kasus aktif, 0,0027 untuk kasus pemulihan, dan 0,001 untuk kasus kematian kumulatif. Penelitian ini berbeda dengan fokus pada prediksi produksi perikanan laut tangkap di Laut Arafura, menggunakan analisis regresi deret Fourier dan *Long Short-Term Memory Recurrent Neural Network* (LSTM-RNN) untuk pengelolaan wilayah perikanan laut tangkap. Meskipun topiknya berbeda, kedua penelitian memiliki kesamaan dalam penerapan teknik jaringan saraf berulang (RNN atau LSTM-RNN) untuk meramalkan tren dalam konteks analisis data.

Keempat, Penelitian Brilliansyah dan Kartini (2023) menggunakan model RNN-LSTM untuk meramalkan tenaga listrik jangka pendek berdasarkan data cuaca, dengan hasil akurasi MSE sebesar 0,0139 dan MAPE sebesar 31,87%. Penelitian tersebut menunjukkan peningkatan hasil peramalan menggunakan metode LSTM untuk tenaga surya perumahan dan memperlihatkan potensi perbandingan dengan metode lain. Perbedaannya, penelitian ini fokus pada perhitungan produksi perikanan laut tangkap dengan menggabungkan analisis regresi deret Fourier dan LSTM-RNN untuk pengelolaan wilayah perikanan laut tangkap di perairan Laut Arafura. Meskipun berbeda dalam konteks aplikasi, keduanya memiliki persamaan dalam menggunakan metode *Long Short-Term Memory*

Recurrent Neural Network (LSTM-RNN) untuk menganalisis data dalam konteks peramalan atau prediksi.

Kelima, Penelitian sebelumnya oleh Ni Putu Ayu Mirah Mariati, I. Nyoman Budiantara, dan Vita Ratnasari (2020) telah mengusulkan metode estimator campuran untuk regresi nonparametrik dengan menggabungkan *smoothing spline* dan seri Fourier. Penelitian ini melibatkan eksperimen pada data simulasi dengan dua fungsi berbeda dan ukuran sampel 100, menggunakan Minimum GCV untuk pemilihan model terbaik. Dalam konteks yang spesifik, penelitian ini bertujuan untuk membandingkan penggunaan regresi deret Fourier dan *Long Short-Term Memory Recurrent Neural Network* (LSTM-RNN) dalam prediksi produksi perikanan laut tangkap di Perairan Laut Arafura. Penelitian ini fokus pada aspek aplikatif dan menggunakan deret Fourier untuk menganalisis data regresi nonparametrik, sekaligus mempertimbangkan perbandingan dengan metode LSTM-RNN.

Terakhir, Penelitian Rina Julita dan Mujiono (2019) menyoroti keefektifan teknologi penginderaan jauh, khususnya sensor satelit MODIS, dalam memprediksi zona potensial penangkapan ikan. Studi ini menekankan pentingnya informasi zona penangkapan untuk meningkatkan efisiensi dan efektivitas penangkapan ikan, dengan merinci perlunya penelitian lebih lanjut untuk meningkatkan akurasi prediksi zona penangkapan. Penelitian yang akan dilakukan ini, mengembangkan pendekatan yang lebih kompleks dengan melibatkan analisis regresi deret fourier dan LSTM-RNN, selain pemetaan ZPPI. Meskipun keduanya memfokuskan pada estimasi zona potensial penangkapan ikan dengan menggunakan citra satelit Modis Aqua, penelitian ini menambah kompleksitas dengan pendekatan analisis yang lebih luas.

Berikut ini disajikan tabel mengenai penelitian terdahulu yang pernah dilakukan oleh beberapa peneliti sebelumnya.

Tabel 2. 1 Hasil Penelitian Terdahulu

No.	Nama Penulis dan Judul Penelitian	Metode Penelitian	Ringkasan Hasil Penelitian	Perbedaan	Persamaan
1	Eros Fikri Syahram, M. Machmud Effendy, Novendra Setyawan (2021), <i>Sun Position Forecasting</i> Menggunakan Metode RNN – LSTM Sebagai Referensi Pengendalian Daya Solar Cell	Penelitian kuantitatif dengan pendekatan prediktif dan menggunakan metode RNN dengan struktur <i>Long Short-Term Memory</i> (LSTM).	RNN-LSTM efektif untuk prediksi posisi matahari, optimalisasi tenaga surya.	Fokus penelitian berbeda, penelitian ini mengkombinasikan regresi deret Fourier dengan LSTM-RNN, dan Penelitian ini juga mengembangkan ZPPI.	Keduanya menggunakan LSTM-RNN untuk analisis data dan terkait dengan prediksi berbasis data.
2	Anang Dwi Purwanto, Dhia Puspa Ramadhani (2020), Analisis Zona Potensi Penangkapan Ikan (ZPPI) Berdasarkan Citra Satelit Suomi NPP-VIIRS (Studi Kasus: Laut Arafura)	Penelitian Kuantitatif dengan metode regresi statistik dengan pendekatan <i>Non-Linear Multi Channel SST</i> (NLSST).	Penelitian tersebut berhasil mengidentifikasi ZPPI di Laut Arafura menggunakan data citra satelit dengan pendekatan regresi statistik NLSST, menunjukkan keragaman dan potensi signifikan untuk penangkapan ikan.	1) Pendekatan <i>Non-Linear Multi Channel SST</i> , penelitian ini menggunakan regresi deret Fourier dan LSTM-RNN. 2) Penelitian ini melibatkan klorofil-a dan salinitas air laut sebagai parameter, yang tidak disebutkan dalam penelitian terdahulu.	1) Keduanya berfokus pada Laut Arafura dan identifikasi ZPPI. 2) Kedua studi menggunakan citra satelit dan data penginderaan jauh.
3	Akhdan Aziz Ghazi, Ayu Aprianti, Ahmad Dzaki Putra Dimas, Rifky Fauzi (2022), Analisis Prediksi Data Kasus Covid-19 di Provinsi Lampung Menggunakan Recurrent Neural Network (RNN)	Pendekatan kuantitatif dengan metode <i>Recurrent Neural Network</i> (RNN).	Model RNN efektif dalam memprediksi kasus Covid-19 di Provinsi Lampung.	Subjek dan sumber data yang berbeda (kesehatan dan perikanan) dan metodologi analisis yang berbeda (RNN murni sedangkan penelitian ini kombinasi Regresi Fourier dan LSTM-RNN).	Keduanya menggunakan teknik neural network (RNN dan LSTM-RNN) dalam analisis data dan fokus pada prediksi berdasarkan data historis.
4	Krisna Taufik Brilliansyah dan Unit Three Kartini (2023), Peramalan Jangka Sangat	Pendekatan kuantitatif dengan menggunakan metode <i>Recurrent</i>	Penelitian tersebut mengembangkan model RNN-LSTM untuk peramalan	Penelitian tersebut fokus pada peramalan daya listrik PLTS berdasarkan data meteorologi,	Kedua penelitian menggunakan LSTM-RNN dalam analisisnya

	Pendek Daya Listrik PLTS On Grid Rumah Tinggal Menggunakan Metode Recurrent Neural Network Long Short-Term Memory Berdasarkan Data Meteorologi	<i>Neural Network Long Short-Term Memory (RNN-LSTM)</i>	daya listrik PLTS jangka sangat pendek, menggunakan data meteorologi, dengan akurasi tinggi, mendukung optimasi penggunaan energi surya berdasarkan kondisi cuaca.	sedangkan penelitian ini fokus pada prediksi produksi perikanan laut tangkap berdasarkan data penginderaan jauh, dan penelitian ini mengkombinasikan regresi deret Fourier dengan LSTM-RNN serta pengembangan ZPPI.	dan Fokus pada penggunaan data <i>time-series</i> .
5	Ni Putu Ayu Mirah Mariati, I. Nyoman Budiantara, dan Vita Ratnasari (2020), <i>Combination Estimation of Smoothing Spline and Fourier Series in Nonparametric Regression</i>	Pendekatan kuantitatif dengan metode kombinasi estimasi smoothing spline dan Fourier series dalam regresi nonparametrik	Penelitian tersebut mengembangkan estimator gabungan smoothing spline dan deret Fourier dalam regresi nonparametrik, menunjukkan efektivitas tinggi dalam analisis data berpola campuran dan berulang.	Penelitian ini mengkombinasikan regresi Fourier dengan LSTM-RNN, sedangkan penelitian tersebut menggabungkan smoothing spline dengan seri Fourier untuk model regresi nonparametrik.	Keduanya menggunakan metode regresi nonparametric dan Implementasi deret Fourier dalam analisis data.
6	Rina Julita dan Mujiono (2019), Estimasi Zona Potensial Penangkapan Ikan (ZPPI) Provinsi Bengkulu Menggunakan Citra Satelit Modis Aqua	Pendekatan <i>mixed method</i> , metode kualitatif melalui wawancara dengan nelayan dan metode kuantitatif yang berfokus pada pengolahan dan analisis citra satelit MODIS Aqua	Penelitian tersebut berhasil memetakan zona potensial penangkapan ikan di Bengkulu, menggunakan citra satelit MODIS Aqua dan mengkombinasikan analisis klorofil-a dan suhu permukaan laut dengan data dari wawancara.	Penelitian terdahulu di perairan Bengkulu, sedangkan penelitian ini di Laut Arafura dengan menggunakan teknik analisis data regresi deret Fourier dan LSTM-RNN. Penelitian ini lebih kompleks, mencakup prediksi produksi perikanan laut tangkap dan pengembangan ZPPI, sementara penelitian terdahulu hanya fokus pada pemetaan ZPPI.	Kedua penelitian menggunakan data penginderaan jauh dan mempertimbangkan parameter suhu permukaan laut dan klorofil-a.

Sumber: Peneliti (2023)

2.3 Kerangka Pemikiran

Dalam Penelitian ini, Peneliti akan menjelaskan kerangka pemikiran yang menjadi landasan konseptual dan teoritis untuk memandu Penelitian ini. Kerangka pemikiran ini akan memberikan kerangka acuan yang jelas untuk menganalisis data yang dikumpulkan dan menjawab pertanyaan Penelitian.

Penelitian ini bertujuan untuk mengembangkan prediksi produksi perikanan laut tangkap berbasis penginderaan jauh di Laut Arafura menggunakan Analisis Regresi Deret Fourier dan *Long Short-Term Memory Recurrent Neural Network* (LSTM-RNN). Latar belakang penelitian didasarkan pada pentingnya Laut Arafura sebagai wilayah perairan yang produktif dan strategis dalam produksi perikanan. Ancaman seperti *illegal fishing*, *overfishing*, dan aktivitas merusak lainnya telah mengancam keberlanjutan industri perikanan di wilayah ini.

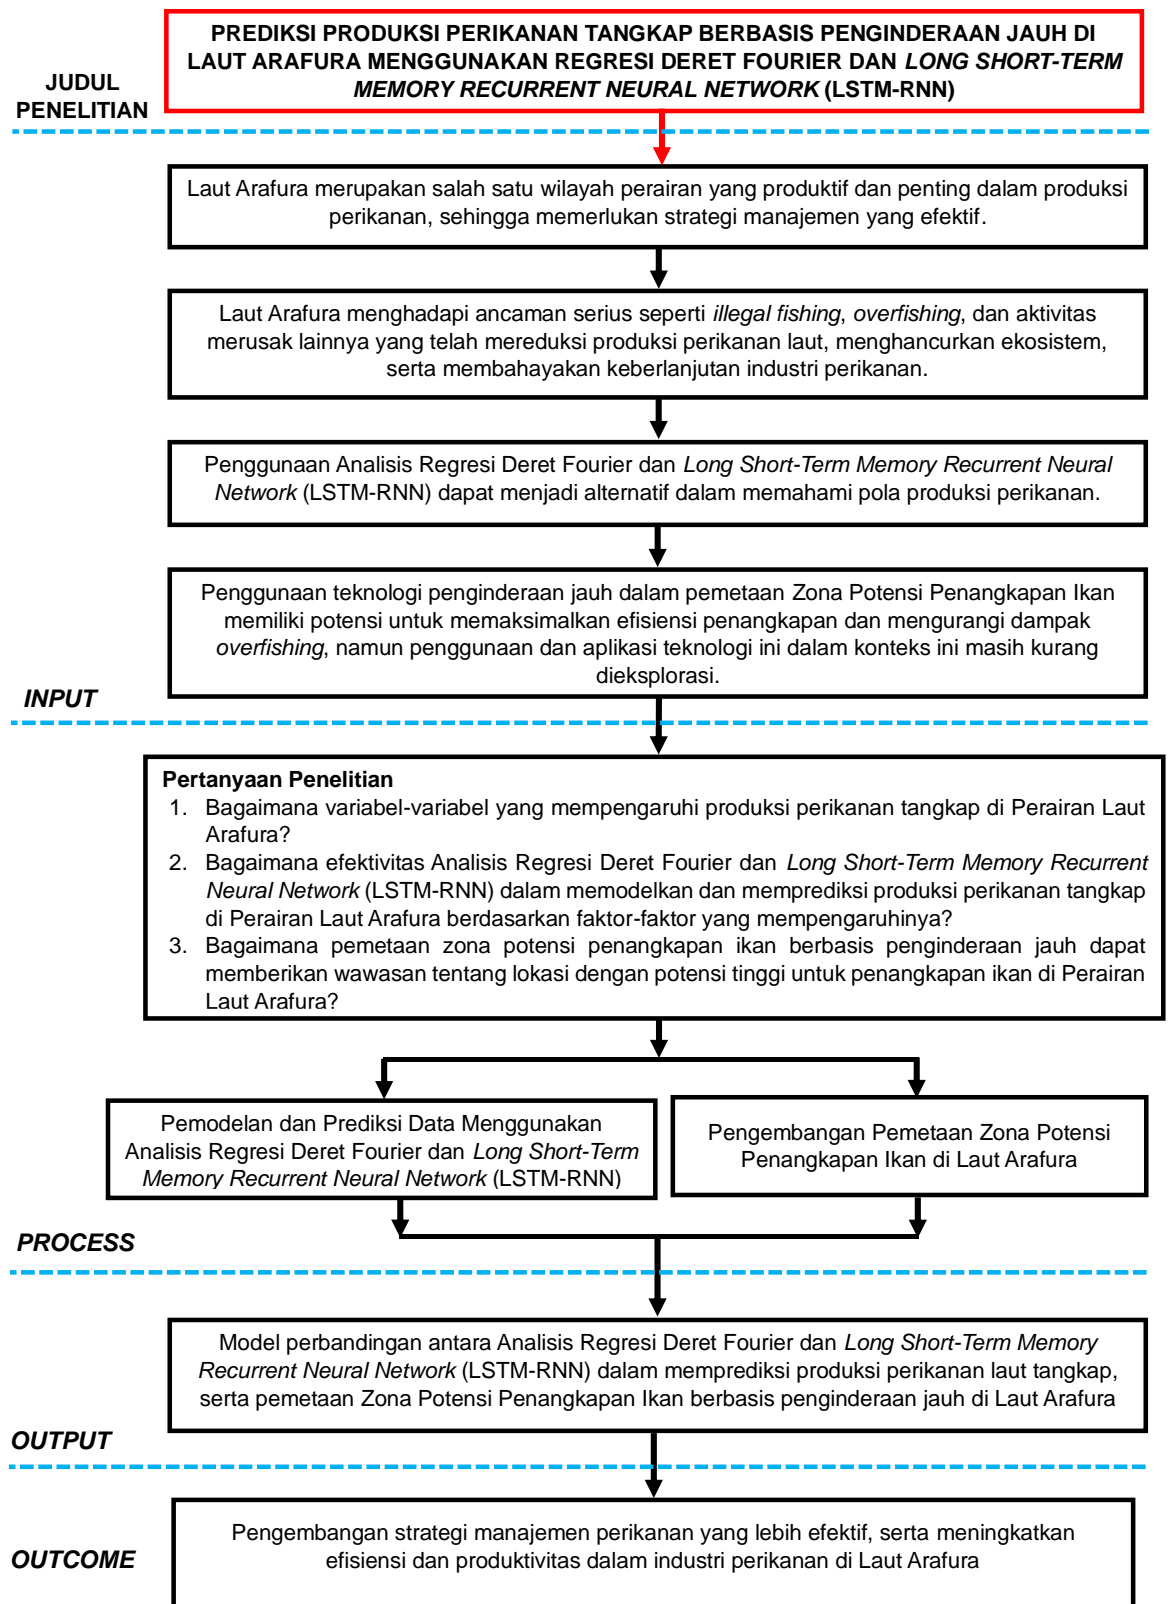
Analisis Regresi Deret Fourier dan LSTM-RNN dianggap sebagai alternatif efektif dalam memahami pola produksi perikanan. Pertanyaan penelitian dirumuskan untuk mengevaluasi efektivitas kedua metode tersebut dalam memodelkan dan memprediksi produksi perikanan laut tangkap di Laut Arafura serta mengidentifikasi variabel-variabel yang memengaruhi produksi tersebut. Selain itu, penelitian ini juga bertujuan untuk mengeksplorasi potensi penggunaan teknologi penginderaan jauh dalam pemetaan Zona Potensi Penangkapan Ikan untuk meningkatkan efisiensi penangkapan dan mengurangi dampak *overfishing*.

Langkah pertama penelitian ini mencakup pemahaman kondisi dan tantangan di Laut Arafura, termasuk ancaman terhadap keberlanjutan perikanan. Selanjutnya, analisis regresi deret Fourier dan LSTM-RNN diterapkan pada data produksi perikanan untuk menjawab pertanyaan penelitian. Metode ini diharapkan dapat memberikan wawasan tentang variabel-variabel yang signifikan dalam memengaruhi produksi perikanan.

Penggunaan teknologi penginderaan jauh akan dilibatkan untuk memetakan Zona Potensi Penangkapan Ikan di Laut Arafura. Penelitian ini

diharapkan menghasilkan model perbandingan antara analisis regresi deret Fourier dan LSTM-RNN dalam memprediksi produksi perikanan. Hasil penelitian ini diharapkan dapat memberikan kontribusi pada pengembangan strategi manajemen perikanan yang lebih efektif, meningkatkan efisiensi penangkapan, dan memperbaiki produktivitas industri perikanan di Laut Arafura secara berkelanjutan.

Diagram alir berikut ini menggambarkan dengan jelas kerangka pemikiran yang mendasari penelitian ini. Mulai dari identifikasi masalah hingga pengembangan metodologi, setiap langkahnya terstruktur secara sistematis. Diagram ini menjadi panduan visual yang membantu dalam memahami alur logis dan urutan langkah-langkah yang perlu diambil dalam menghadapi permasalahan penelitian.



Gambar 2. 6 Kerangka Berpikir
Sumber: Peneliti (2023)