BAB 2

LANDASAN TEORI

2.1 Komponen Peralatan Pancing

Sistem rekomendasi ini hanya memfokuskan pada empat jenis peralatan pancing utama, yaitu joran, reel, senar, dan kail. Keempat komponen ini menjadi fokus karena secara langsung memengaruhi kemampuan alat dalam menahan beban, mengontrol tarikan ikan, serta menyesuaikan dengan kondisi perairan dan spesies sasaran. Spesifikasi teknis seperti panjang joran, gear ratio reel, kekuatan tarik senar, dan ukuran kail dapat diukur secara kuantitatif sehingga mudah diolah dalam model rekomendasi. Penelitian terbaru menegaskan bahwa fokus pada kombinasi alat utama ini memberikan pengaruh signifikan terhadap hasil tangkapan, sementara aksesoris tambahan seperti pelampung atau umpan lebih dipengaruhi oleh preferensi pengguna dan sulit distandarisasi dalam algoritma [1, 9, 2].

Dengan membatasi ke empat komponen utama ini, model rekomendasi menjadi lebih sederhana dan efektif tanpa perlu menangani kompleksitas parameter yang tidak kritis. Komponen lain tidak dimasukkan karena variabilitasnya sangat tinggi dan dampaknya terhadap rekomendasi teknis dianggap minimal dalam konteks penelitian ini. Oleh karena itu, joran, reel, senar, dan kail dijadikan sebagai basis utama dalam sistem rekomendasi yang dikembangkan.

2.1.1 Joran

Joran merupakan batang utama dalam alat pancing yang berfungsi sebagai tuas dalam melempar dan menarik umpan atau ikan. Joran umumnya terbuat dari material seperti fiberglass, grafit, atau karbon komposit, yang memengaruhi fleksibilitas dan kekuatannya. Panjang joran bervariasi tergantung teknik dan lokasi memancing. Dalam konteks penelitian ini, joran yang tersedia memiliki panjang antara 120 hingga 180 cm. Joran pendek (sekitar 120 cm) cenderung digunakan pada area sempit seperti empang, sementara joran panjang (hingga 180 cm) lebih sesuai untuk jarak lempar yang jauh, seperti di sungai atau laut terbuka [10].

Gambar 2.1. Contoh joran

2.1.2 Reel

Reel adalah mekanisme penggulung senar yang dipasang pada joran. Fungsinya meliputi pengaturan panjang senar, kontrol saat melempar umpan, serta penarikan ikan. Ukuran reel dinyatakan dalam angka seperti 1000, 2000, hingga 8000. Makin besar angka, makin besar kapasitas spool dan kekuatan drag-nya. Dalam sistem ini, reel yang digunakan bervariasi dari ukuran 1000 (untuk ikan kecil di empang atau sungai) hingga 8000 (untuk ikan besar di laut). Ukuran reel berpengaruh terhadap kekuatan pancingan secara keseluruhan dan harus disesuaikan dengan jenis joran, senar, dan lokasi memancing [11].

U N I V E R S I T A S
M U L T I M E D I A
N U S A N T A R A

Gambar 2.2. Contoh reel

2.1.3 Senar

Senar pancing adalah penghubung utama antara reel dan kail, serta berfungsi sebagai media transmisi gaya saat ikan tertarik. Terdapat beberapa jenis senar, seperti monofilamen, fluorocarbon, dan braided, yang berbeda dari segi kelenturan dan kekuatan. Ukuran senar ditentukan oleh diameter (dalam mm) dan kekuatan tarik (dalam kg atau lbs). Dalam dataset sistem ini, senar memiliki diameter mulai dari 0,12 mm hingga 0,60 mm, yang berkorelasi positif terhadap kekuatan senar. Senar berdiameter kecil digunakan untuk ikan ringan di empang atau sungai, sementara senar besar cocok untuk laut [12].

U N I V E R S I T A S
M U L T I M E D I A
N U S A N T A R A

Gambar 2.3. Contoh senar

2.1.4 Kail

Kail adalah bagian akhir dari rangkaian alat pancing yang berfungsi untuk mengait umpan dan menangkap ikan. Ukuran kail biasanya ditandai dengan angka dari 1 hingga 10, di mana ukuran 1 merupakan kail terbesar dan 10 adalah yang terkecil. Pemilihan ukuran kail ditentukan oleh ukuran mulut ikan target serta teknik memancing yang digunakan. Dalam konteks sistem ini, variasi ukuran kail digunakan untuk mencocokkan preferensi pengguna terhadap target berat ikan [11].

Gambar 2.4. Contoh kail

2.2 Sistem Rekomendasi

Sistem rekomendasi merupakan sistem berbasis data yang memberikan saran kepada pengguna dalam memilih item berdasarkan preferensi, kebutuhan, atau kondisi tertentu. Terdapat beberapa pendekatan utama, yaitu *content-based filtering*, *collaborative filtering*, dan *context-aware recommendation*. Dalam penelitian ini, sistem dikembangkan menggunakan pendekatan *attribute-based* dan *context-aware*, yaitu mempertimbangkan informasi lokasi memancing, batasan anggaran, dan target berat ikan pengguna untuk menentukan rekomendasi kombinasi alat pancing [3].

2.3 Rekomendasi Berbasis Atribut dan Konteks

Pendekatan *context-aware recommendation* memperkaya rekomendasi dengan mempertimbangkan dimensi tambahan seperti lokasi, waktu, perangkat, atau kondisi spesifik pengguna. Pada penelitian ini, sistem menggunakan tiga konteks utama: jenis lokasi memancing (empang, sungai, laut), anggaran pengguna, dan target berat ikan. Selain itu, sistem ini juga berfokus pada pengguna dengan sumber daya terbatas, sehingga mengadopsi prinsip *budget-aware recommendation* untuk memberikan saran realistis berdasarkan batasan harga pengguna [5, 4].

2.4 Rekomendasi Kombinasi Produk

Sistem ini tidak hanya merekomendasikan satu item, tetapi kombinasi alat pancing lengkap yang terdiri dari joran, reel, senar, dan kail. Model ini termasuk dalam kategori *bundle recommendation*, di mana beberapa item disarankan secara bersamaan sebagai satu set yang optimal untuk konteks pengguna. Tantangan dalam rekomendasi bundel melibatkan optimisasi kompatibilitas antar produk, serta adaptasi terhadap preferensi dan kendala pengguna seperti performa alat dan harga [13].

2.5 Algoritma *K-Nearest Neighbors* (KNN)

K-Nearest Neighbors adalah algoritma berbasis jarak yang digunakan untuk menemukan sejumlah *item* paling mirip dari kumpulan data. Dalam proyek ini, digunakan `NearestNeighbors` dari pustaka `scikit-learn` untuk menemukan

kombinasi alat pancing yang paling dekat (dalam ruang vektor fitur) terhadap preferensi pengguna.

Jarak dihitung dalam ruang tiga dimensi: lokasi memancing (hasil *Label Encoding*), anggaran total pengguna, dan target berat ikan. Fungsi jarak yang digunakan adalah *Euclidean distance*, dengan rumus:

$$d(x_i, x_j) = \sqrt{\sum_{k=1}^n (x_{ik} - x_{jk})^2} \quad (2.1)$$

di mana x_i dan x_j adalah vektor kombinasi alat pancing, dan $n = 3$ (jumlah fitur).

Fitur lokasi dikodekan menggunakan *Label Encoding* sebagai berikut: empang = 0, sungai = 1, dan laut = 2.

Karena sistem tidak memiliki label target, pendekatan ini bersifat *unsupervised* dan hanya berfokus pada kemiripan spasial antar data [6].

2.6 Algoritma Pemanding

Untuk menilai keefektifan pendekatan KNN, dilakukan perbandingan terhadap dua algoritma lain, yaitu *K-Means Clustering* dan *Decision Tree Classifier*, yang masing-masing mewakili pendekatan *unsupervised* dan *supervised learning*.

2.6.1 K-Means Clustering

K-Means adalah algoritma *unsupervised learning* yang digunakan untuk melakukan pengelompokan berdasarkan kemiripan data. Model membagi data ke dalam k kluster dengan meminimalkan jarak antara data dan pusat kluster (μ_i) sebagaimana dirumuskan pada Persamaan 2.2:

$$J = \sum_{i=1}^k \sum_{x_j \in C_i} \|x_j - \mu_i\|^2 \quad (2.2)$$

Dalam penelitian ini, *KMeans* digunakan untuk membandingkan hasil pengelompokan terhadap distribusi kombinasi alat pancing berdasarkan fitur yang sama dengan KNN, yaitu lokasi, anggaran, dan target berat ikan.

2.6.2 Decision Tree Classifier

Decision Tree adalah algoritma *supervised learning* yang digunakan untuk klasifikasi. Meskipun sistem utama tidak menggunakan label, model pohon keputusan dibangun sebagai pembanding dengan memanfaatkan label hasil kluster K-Means sebagai target kelas. Pemisahan data dilakukan berdasarkan nilai maksimum dari pengukuran seperti Gini Index pada Persamaan 2.3:

$$Gini(D) = 1 - \sum_{i=1}^n p_i^2 \quad (2.3)$$

2.7 Pra-pemrosesan Data

2.7.1 Normalisasi

Fitur numerik seperti anggaran dan target berat ikan dinormalisasi menggunakan metode *Min-Max Normalization* agar memiliki skala antara 0 dan 1, sebagaimana pada Persamaan 2.4:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (2.4)$$

Normalisasi penting untuk algoritma berbasis jarak agar tidak bias terhadap fitur dengan skala lebih besar.

2.7.2 Encoding Kategorikal

Fitur kategorikal seperti lokasi memancing dikonversi menjadi nilai numerik melalui *Label Encoding*. Setiap kategori diubah menjadi integer agar dapat diproses dalam perhitungan jarak dan pemodelan. Urutan encoding yang digunakan adalah empang = 0, sungai = 1, dan laut = 2 [14].

2.8 Evaluasi Model Rekomendasi

Evaluasi model rekomendasi dilakukan melalui dua pendekatan utama, yaitu **evaluasi teknis** dan **evaluasi berbasis pengguna**. Evaluasi teknis berfokus pada pengukuran kinerja algoritma secara kuantitatif, sedangkan evaluasi berbasis

pengguna menilai tingkat penerimaan, kemudahan penggunaan, serta kepuasan pengguna terhadap sistem. Pendekatan ganda ini direkomendasikan dalam penelitian sistem rekomendasi untuk memastikan model tidak hanya optimal secara matematis, tetapi juga relevan dan bermanfaat bagi pengguna akhir [15, 16].

2.8.1 Metrik Evaluasi Teknis

A Silhouette Score

Silhouette Score adalah metrik yang digunakan untuk mengukur kualitas pemisahan antar kluster pada hasil pengelompokan. Metrik ini mempertimbangkan keseimbangan antara *cohesion* (kedekatan titik dengan kluster yang sama) dan *separation* (jarak titik terhadap kluster terdekat) [17]. Nilai mendekati 1 menunjukkan pemisahan kluster yang baik, sedangkan nilai mendekati -1 menunjukkan kemungkinan salah klasifikasi.

$$s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}} \quad (2.5)$$

Pada Persamaan 2.5, $a(i)$ adalah rata-rata jarak antara titik i dengan seluruh titik dalam kluster yang sama, sedangkan $b(i)$ adalah rata-rata jarak antara titik i dengan seluruh titik pada kluster terdekat. Silhouette Score banyak digunakan pada *unsupervised learning* karena tidak memerlukan label referensi [18].

B Principal Component Analysis (PCA)

Principal Component Analysis (PCA) adalah teknik reduksi dimensi yang memproyeksikan data berdimensi tinggi ke dimensi lebih rendah sambil mempertahankan variansi terbesar dari data [19, 20]. PCA sering digunakan dalam evaluasi sistem rekomendasi untuk memvisualisasikan distribusi data atau hasil klusterisasi dalam dua dimensi sehingga memudahkan interpretasi [21].

$$Z = XW \quad (2.6)$$

Pada Persamaan 2.6, X adalah matriks data asli, W adalah matriks vektor eigen dari matriks kovarians X , dan Z adalah hasil transformasi data pada ruang komponen utama.

C Adjusted Rand Index (ARI)

Adjusted Rand Index (ARI) digunakan untuk mengukur kesesuaian hasil pengelompokan dengan label acuan, dengan memperhitungkan kemungkinan kesesuaian yang terjadi secara acak [22, 23]. Nilai ARI berada pada rentang -1 hingga 1, di mana nilai 1 menunjukkan kesesuaian sempurna.

$$ARI = \frac{RI - E[RI]}{\max(RI) - E[RI]} \quad (2.7)$$

Pada Persamaan 2.7, *RI* adalah *Rand Index* dan $E[RI]$ adalah ekspektasi dari *RI* pada pengelompokan acak [24].

2.8.2 Evaluasi Berbasis Pengguna

A Kerangka *Technology Acceptance Model* (TAM)

Technology Acceptance Model (TAM) adalah kerangka konseptual yang menjelaskan faktor-faktor yang memengaruhi penerimaan teknologi. Model ini menekankan dua konstruk utama:

1. **Perceived Ease of Use (PEOU)**: tingkat keyakinan pengguna bahwa penggunaan sistem tidak akan memerlukan usaha yang berlebihan.
2. **Perceived Usefulness (PU)**: sejauh mana pengguna percaya bahwa sistem akan meningkatkan kinerja atau memberikan manfaat signifikan.

Menurut [25, 26], kedua konstruk ini memiliki pengaruh langsung terhadap *Behavioral Intention* pengguna untuk mengadopsi suatu teknologi. TAM banyak digunakan dalam evaluasi sistem rekomendasi karena mampu mengidentifikasi faktor-faktor adopsi yang relevan dengan persepsi pengguna.

B Prinsip Usability dan User Experience (UX)

Prinsip *usability* mencakup kemudahan sistem untuk dipelajari, digunakan, dan diingat oleh pengguna, serta minimnya tingkat kesalahan saat digunakan [27]. Sedangkan *user experience* (UX) berfokus pada persepsi menyeluruh pengguna terhadap interaksi dengan sistem, meliputi aspek kepuasan, kenyamanan, dan kesenangan [28]. Indikator umum dalam evaluasi usability dan UX mencakup:

- Kemudahan navigasi dan interaksi.
- Kejelasan informasi dan tata letak antarmuka.
- Konsistensi desain dan kecepatan respon.
- Tingkat kepuasan keseluruhan saat menggunakan sistem.

C Pendekatan User-Centered Evaluation

User-centered evaluation adalah pendekatan evaluasi yang menempatkan pengguna sebagai fokus utama dalam menilai kualitas dan keberhasilan suatu sistem. Pendekatan ini menggabungkan metode kuantitatif (misalnya kuesioner berbasis skala Likert) dan kualitatif (misalnya wawancara atau umpan balik terbuka) untuk memperoleh gambaran menyeluruh mengenai pengalaman pengguna [29, 30].

D Skala Likert

Skala Likert merupakan metode pengukuran persepsi dan sikap responden terhadap suatu pernyataan dengan rentang nilai tertentu [31]. Skala 5 poin yang digunakan dalam penelitian ini adalah:

Tabel 2.1. Bobot Nilai pada Skala Likert 5 Poin

Kategori Jawaban	Bobot Nilai
Sangat Tidak Setuju (STS)	1
Tidak Setuju (TS)	2
Netral (N)	3
Setuju (S)	4
Sangat Setuju (SS)	5

Penggunaan skala ini memudahkan analisis kuantitatif terhadap persepsi pengguna dan memungkinkan identifikasi pola penerimaan serta tingkat kepuasan terhadap sistem [32].

E Metode Penghitungan Skor Likert

Analisis kuantitatif data kuesioner skala Likert dilakukan dengan memetakan setiap kategori jawaban ke nilai numerik tetap ($STS=1$, $TS=2$, $N=3$,

S=4, SS=5) [33, 34, 35].

E.1 Notasi dan Data Dasar.

Misalkan:

- a = algoritma yang dievaluasi (*KNN*, *KMeans*, atau *Decision Tree*);
- $m = 1, \dots, M$ = indeks indikator penilaian (pada penelitian ini $M = 6$);
- $c \in \{1, \dots, 5\}$ = kategori jawaban pada skala Likert (1=STS, ..., 5=SS) dengan bobot $v_c = c$;
- $f_{a,m,c}$ = jumlah responden yang memilih kategori c untuk algoritma a pada indikator m ;
- $n_m = \sum_{c=1}^5 f_{a,m,c}$ = jumlah responden yang memberikan jawaban valid untuk indikator m .

E.2 Rumus 1: Rata-rata Skor Likert per Indikator.

Rumus ini digunakan untuk menghitung skor rata-rata pada setiap indikator penilaian untuk suatu algoritma:

$$\bar{S}_{a,m} = \frac{1}{n_m} \sum_{c=1}^5 f_{a,m,c} v_c \quad (2.8)$$

Interpretasi:

- Pembilang menghitung **total skor** yang diperoleh dari hasil kali frekuensi jawaban ($f_{a,m,c}$) dan bobot kategori (v_c).
- Penyebut n_m membagi total skor tersebut dengan jumlah responden, sehingga menghasilkan **nilai rata-rata** untuk indikator tersebut.

E.3 Rumus 2: Skor Akhir per Algoritma.

Setelah mendapatkan skor rata-rata untuk setiap indikator, skor akhir suatu algoritma dihitung dengan rata-rata dari seluruh indikator:

$$\bar{S}_a = \frac{1}{M} \sum_{m=1}^M \bar{S}_{a,m} \quad (2.9)$$

Interpretasi:

- Rumus ini memberikan **nilai agregat** kinerja algoritma berdasarkan semua indikator penilaian.
- Skor akhir $\bar{S}_a$ berada pada rentang 1–5, di mana nilai lebih tinggi berarti penerimaan pengguna lebih baik.

E.4 Rumus 3: Skor Akhir dengan Bobot Indikator .

Jika setiap indikator memiliki bobot kepentingan berbeda (w_m), maka skor akhir dihitung dengan rata-rata tertimbang:

$$\bar{S}_a^{(w)} = \sum_{m=1}^M w_m \bar{S}_{a,m} \quad (2.10)$$

Syarat:

$$\sum_{m=1}^M w_m = 1$$

Bobot ini berguna bila peneliti ingin memberi prioritas pada indikator tertentu.

E.5 Rumus 4: Transformasi Skor ke Persentase

Untuk mempermudah interpretasi, skor Likert dapat dikonversi menjadi persentase:

$$S_{a,m}^{(\%)} = \frac{\sum_{c=1}^5 f_{a,m,c} v_c}{5 n_m} \times 100\%, \quad S_a^{(\%)} = \frac{1}{M} \sum_{m=1}^M S_{a,m}^{(\%)} \quad (2.11)$$

Interpretasi:

- Penyebut $5n_m$ adalah **skor maksimum** yang mungkin dicapai pada indikator m .
- Persentase memudahkan pembaca membandingkan hasil antar algoritma secara intuitif (0–100%).

E.6 Contoh Perhitungan.

Pada indikator pertama untuk *KNN*, 5 responden memilih SS:

$$\bar{S}_{KNN,1} = \frac{5 \times 5}{5} = 5,00, \quad S_{KNN,1}^{(\%)} = \frac{5 \times 5}{5 \times 5} \times 100\% = 100\%.$$

2.9 Teknologi Pendukung

2.9.1 *Scikit-Learn*

Digunakan untuk implementasi algoritma *KNN*, *KMeans*, dan *Decision Tree*, serta proses pra-pemrosesan seperti normalisasi dan encoding fitur.

2.9.2 *Streamlit*

Digunakan sebagai antarmuka pengguna berbasis web yang interaktif, memungkinkan pengguna menginput lokasi, anggaran, dan target ikan untuk mendapatkan rekomendasi kombinasi alat pancing secara real-time.

2.9.3 *Joblib* dan *Jupyter Notebook*

Joblib digunakan untuk menyimpan model dan objek preprocessing ke dalam format '.pkl', sehingga dapat digunakan ulang tanpa perlu melatih ulang. *Jupyter Notebook* digunakan untuk eksplorasi data, pelatihan dan pengujian model, serta visualisasi hasil evaluasi.

2.10 Tinjauan Penelitian Terdahulu

Sistem rekomendasi berbasis atribut dan preferensi pengguna telah banyak dikembangkan dalam berbagai bidang, khususnya pada domain e-commerce dan media digital. Pendekatan ini memungkinkan sistem memberikan saran produk atau layanan berdasarkan karakteristik spesifik pengguna, seperti lokasi geografis,

anggaran, atau tujuan penggunaan. Penelitian menunjukkan bahwa integrasi konteks dalam sistem rekomendasi—seperti waktu, lokasi, dan suasana—dapat meningkatkan relevansi hasil rekomendasi secara signifikan dibandingkan sistem berbasis user-item tradisional [3]. Hal ini menjadi landasan penting dalam perancangan sistem yang mempertimbangkan informasi lokasi memancing sebagai salah satu faktor utama dalam pemberian saran produk.

Dalam ranah sistem rekomendasi produk fisik, pendekatan rekomendasi kombinasi atau *bundle recommendation* merupakan strategi yang umum diadopsi. Sistem ini menyarankan beberapa item sekaligus yang dirancang untuk saling melengkapi dalam satu konteks penggunaan. Studi pada platform e-commerce menunjukkan bahwa kompatibilitas antar produk menjadi faktor penting dalam keberhasilan sistem rekomendasi bundel [13]. Konsep ini sangat relevan dengan penelitian ini karena sistem tidak hanya merekomendasikan satu produk, melainkan satu set alat pancing lengkap yang mencakup joran, reel, senar, dan kail. Setiap item harus divalidasi kecocokannya satu sama lain serta terhadap konteks lokasi dan target pengguna.

Aspek lain yang mendukung penelitian ini adalah pengaruh anggaran atau keterbatasan biaya dalam sistem rekomendasi. Model yang memperhitungkan batasan harga pengguna dalam proses penyaringan terbukti dapat meningkatkan kepuasan dan efektivitas sistem [4]. Pendekatan serupa diterapkan dalam penelitian ini dengan membatasi hasil rekomendasi agar tetap berada dalam rentang anggaran yang diinput pengguna, tanpa mengorbankan kekuatan dan kecocokan alat.

Dari sisi algoritma, penelitian ini mengadopsi algoritma *K-Nearest Neighbors* (KNN) untuk melakukan pencarian kombinasi alat pancing yang paling mirip dengan preferensi pengguna. KNN merupakan algoritma instance-based yang bekerja dengan mencari tetangga terdekat dalam ruang fitur multidimensi. Algoritma ini sangat sesuai digunakan untuk sistem rekomendasi berbasis kemiripan karena kesederhanaannya dan kemampuannya menangani data tanpa label eksplisit [6]. Selain itu, preprocessing seperti normalisasi menjadi faktor penting untuk mencegah bias terhadap fitur dengan skala berbeda.

Penelitian juga menunjukkan bahwa teknik normalisasi memiliki dampak besar terhadap performa algoritma KNN dan KMeans dalam tugas klasifikasi maupun pengelompokan berbasis jarak [36]. Sementara itu, algoritma seperti *Decision Tree* memiliki keunggulan dalam interpretabilitas model, namun tidak fleksibel dalam menangani data tanpa label target eksplisit, sehingga kurang sesuai untuk sistem rekomendasi yang bersifat unsupervised [37].

Meskipun berbagai studi telah membahas sistem rekomendasi berbasis atribut, bundel produk, hingga algoritma pembandingan seperti KNN, KMeans, dan Decision Tree, belum ditemukan penelitian yang secara spesifik mengembangkan sistem rekomendasi untuk kombinasi peralatan pancing berdasarkan tiga parameter utama: lokasi memancing, budget pengguna, dan target berat ikan. Penelitian ini hadir untuk mengisi kekosongan tersebut dengan menawarkan pendekatan berbasis data yang diperoleh dari toko online dan divalidasi melalui survei pengguna, serta menerapkan metode kombinasi produk secara otomatis untuk menghasilkan saran yang sesuai secara teknis dan kontekstual.