

DAFTAR ISI

Halaman Judul	i
Lembar Pengesahan	ii
Identitas Penelitian	iii
DAFTAR ISI.....	1
DAFTAR TABEL.....	2
DAFTAR GAMBAR.....	3
RINGKASAN PENELITIAN.....	4
BAB 1. PENDAHULUAN	5
BAB 2. TINJAUAN PUSTAKA	8
BAB 3. METODOLOGI PENELITIAN	11
BAB 4. HASIL DAN PEMBAHASAN	16
BAB 5. KESIMPULAN DAN SARAN	25
DAFTAR PUSTAKA	26
LAMPIRAN 1. ROAD MAP PENELITIAN	28
LAMPIRAN 2. LUARAN PENELITIAN.....	30

DAFTAR TABEL

Tabel 4.3.1 Ringkasan Jalur Alternatif Metode Pengembangan Selanjutnya

DAFTAR GAMBAR

- Gambar 2.1.1. Korelasi game difficulty dan player skills terhadap player enjoyment
- Gambar 2.3.1. Ilustrasi metode Meta Learning
- Gambar 3.2.2.1 Diagram alir proses gaming emotion recognition menggunakan meta-learning
- Gambar 3.2.2.2 Arsitektur Model Machine Learning berbasis metode Meta Learning
- Gambar 3.2.4.1 Infratraktur proses pengumpulan beserta pertukaran data yang terjadi
- Gambar 3.3.1 Confusion Matrix pada hasil metode Machine Learning
- Gambar 4.3.1 Dataset CK+
- Gambar 4.3.2. Dataset JAFFE
- Gambar 4.3.3 Dataset Affectnet
- Gambar 4.3.4 Dataset Deepface
- Gambar 4.3.5 Hasil ekstrak 5 informasi landmark pada RetinaFace
- Gambar 4.3.6 Struktur Direktori Dataset
- Gambar 4.3.7 Proses Pengolahan Data Meta-Training dan Meta-Testing

RINGKASAN PENELITIAN

Dalam penelitian ini telah dirumuskan beberapa pertanyaan riset berikut: (1) bagaimana mengenali emosi-emosi tertentu dari suatu player dalam game berbasis sistem komputasi sesuai dengan kategori emosi yang telah ditetapkan (2) bagaimana membangun sistem komputasi yang dapat belajar (melalui tahapan machine learning) menggunakan metode Meta Learning dari kumpulan citra / image yang dikumpulkan sebagai data set percobaan untuk dapat mengenali emosi-emosi player sesuai rumusan masalah di atas, serta (3) bagaimana menilai tingkat keberhasilan dari sistem komputasi tersebut agar dapat ditentukan aksi selanjutnya dari sistem untuk menyesuaikan konten / tingkat kesulitan game agar meningkatkan gaming experience dari player. Penelitian ini bertujuan: (1) melakukan perancangan Sistem Pendeteksi Emosi pada Game berbasis metode Meta Learning serta (2) mengimplementasikan prototipe sistem / perangkat lunak pendeteksi emosi pada game berbasis metode Meta Learning. Penelitian ini memiliki manfaat: (1) menambah referensi literatur penelitian pendeteksian emosi pada aplikasi game menggunakan metode machine learning khususnya metode meta learning yang dapat dimanfaatkan tidak hanya di domain gaming namun dapat diterapkan juga di domain lain seperti pembelajaran interaktif atau pembelajaran berbasis gamification, (2) menambah kapasitas personil dan sarana dalam lingkup Laboratorium / Kelompok Bidang Keilmuan Sistem Komputer di Program Studi Teknik Elektro dalam mengembangkan prototipe sistem berbasis Machine Learning, secara spesifik untuk meningkatkan evaluasi pembelajaran melalui penilaian ketertarikan peserta belajar dalam mengikuti modul interaktif. Prototipe sistem ini diharapkan dapat terus dikembangkan untuk diaplikasikan dalam proses pembelajaran di Prodi, Fakultas maupun Universitas, serta (3) menambah referensi literatur penelitian institusi perguruan tinggi di Indonesia di bidang machine learning / meta learning. Selain itu prototipe yang akan dihasilkan pada Tingkat kesiapterapan Teknologi (TkT 3) dapat terus dikembangkan menjadi sistem yang lebih siap untuk diaplikasikan dalam proses pembelajaran yang lebih luas di luar Institusi pengembang dengan meningkatkan tingkat kesiapterapan teknologi ke tingkatan lebih tinggi. Penelitian ini juga ditargetkan dapat menghasilkan luaran Publikasi di Jurnal Nasional terakreditasi SINTA 4 serta luaran Hak Kekayaan Intelektual berupa Hak Cipta dari prototype perangkat lunak yang dihasilkan. Hasil sementara menunjukkan bahwa dari eksplorasi dataset telah ditemukan 2 metode pendeteksian wajah yang cukup baik yaitu MTCNN dan Retina Face. Selain itu telah dilakukan ujicoba model awal metode pendeteksian emosi melalui ekspresi wajah menggunakan Convolutional Neural Network yang dibandingkan dengan metode PyTorch sebagaimana hasil studi yang dilakukan salah satu anggota Tim yang telah dipublikasikan sebagai hasil studi awal. Luaran wajib yang telah dihasilkan adalah Hak Cipta untuk Poster Metodologi Penelitian yang dapat memberikan gambaran kekhususan topik penelitian ini. Selain itu draft awal publikasi telah dikirimkan untuk review dalam Jurnal Terakreditasi Nasional (SINTA 4).

Kata Kunci :

Game, Gaming, Emotion Recognition, Machine Learning, Meta Learning

BAB 1. PENDAHULUAN

1.1. Latar Belakang

Indonesia telah meluncurkan ‘Making Indonesia 4.0.’ yang diluncurkan oleh Presiden Joko Widodo pada awal April 2018 tersebut, dengan harapan Indonesia dapat mencapai 10 besar ekonomi global pada 2030, serta membangun kembali perindustrian Indonesia ke era baru pada revolusi industri keempat dan merevitalisasi industri nasional secara menyeluruh [1].

Baru-baru ini, Kementerian Perindustrian Indonesia telah merancang 'Membuat Indonesia 4.0' sebagai Peta Jalan Terpadu untuk mengimplementasikan sejumlah strategi untuk memasuki era Industri 4.0. Peta Jalan membutuhkan tindakan kolaboratif di antara banyak pemangku kepentingan yang berkisar dari lembaga pemerintah, asosiasi dan pemain industri, hingga elemen akademik.

Dalam hal ini, sektor industri nasional membutuhkan banyak perbaikan terutama dalam aspek penguasaan teknologi, yang telah menjadi kunci utama untuk bersaing di era industri 4.0. Lima teknologi utama untuk mendukung pengembangan industri 4.0 adalah *Internet of Things*, kecerdasan artifisial, antarmuka manusia-mesin, teknologi robot sensor, dan pencetakan 3D [2].

Terkait dengan visi Indonesia 4.0 tersebut, Menteri Pendidikan dan Kebudayaan Nadiem Makarim menyinggung konsep Revolusi Industri 4.0 yang dikaitkan dengan dunia Pendidikan di Indonesia. Nadiem Makarim membeberkan adanya keterkaitan penting antara Revolusi Industri 4.0 dengan Pendidikan Indonesia yang akan menuju persaingan secara global. Masa depan Indonesia sangat dipengaruhi oleh dunia pendidikan. Mendikbud Nadiem Makarim menyinggung bahwa masa depan bangsa dilihat dari kualitas kaum penerus. Sosok-sosok tersebut tak lain dan tak bukan adalah para generasi muda, anak-anak kita, penerus bangsa. Untuk itu diperlukan adaptasi pada metode penyampaian materi pendidikan dan juga strategi menyiapkan generasi muda penerus tersebut. Digitalisasi teknologi akan menjadi kunci dalam strategi implementasi Industri 4.0 dalam dunia Pendidikan [3].

Salah satu teknologi digital yang merupakan salah satu sarana meningkatkan interaksi dalam proses pembelajaran adalah gamifikasi (*gamification*). Gamifikasi merupakan penggunaan prinsip-prinsip dan elemen utama pada permainan untuk menyampaikan tujuan pembelajaran tertentu [4]. Gamifikasi adalah sebuah metode pembelajaran yang menerapkan dinamika dan mekanika game demi meningkatkan kualitas luaran pembelajaran [5]. Unsur interaktivitas dan keterlibatan dalam permainan game seringkali dapat membantu konsentrasi sehingga dapat dimanfaatkan dalam meningkatkan pembelajaran daring [6,7], sehingga faktor ini menjadi latar belakang diusulkannya topik penelitian ini.

1.2. Perumusan Masalah

Pemanfaatan aplikasi *game* berbasis sistem komputer saat ini sangat marak dilakukan oleh berbagai lapisan masyarakat terutama generasi muda di mana kegiatan “*gaming*” ini mencakup berbagai tema apakah itu merangsang kreativitas (contoh: Minecraft) ataupun strategi dan *teamwork* (contoh Mobile Legend) baik secara *online* (berbasis jaringan komputer / Internet) ataupun *offline* (berbasis stand alone komputer / gawai).

Tidak sering pemain *game* ini (*player*) begitu tertarik dengan sesi permainan dan terpicu juga emosinya dikarenakan interaksi dengan tahapan-tahapan dalam permainan *game* tersebut. Emosi yang dihasilkan bisa berupa emosi positif (tertarik dan gembira) maupun negatif (bosan, frustrasi atau bahkan marah). Suatu game yang merangsang emosi positif dapat bermanfaat untuk meningkatkan semangat dan juga kreativitas. Secara positif teknik-teknik berbasis interaksi *game* atau yang dikenal sebagai “*gamification*” dapat dimanfaatkan pula untuk aplikasi lain seperti dalam domain pembelajaran

dimana peserta belajar diharapkan dapat lebih tertarik dan terserap perhatiannya untuk mengikuti kegiatan pembelajaran.

Oleh karena itu terlihat kebutuhan bagi perancang aplikasi *game* khususnya jika teknik-teknik dan interaksinya diterapkan pada modul pembelajaran secara *online* agar dapat memantau tingkat ketertarikan peserta belajar terhadap materi yang disajikan, apakah tertarik, bosan ataukah frustrasi. Dalam hal ini diperlukan suatu metode deteksi ketertarikan peserta belajar, atau *player* selama berinteraksi dengan modul belajar atau aplikasi *game* tersebut.

Penelitian ini dilatarbelakangi motivasi untuk dapat memantau tingkat ketertarikan peserta belajar selama mengikuti pembelajaran yang berbasis metode “*gamification*” sehingga pada penelitian ini akan diteliti terlebih dahulu metode-metode dasar pendeteksian emosi dalam berinteraksi dengan modul pembelajaran yang dilakukan pada tahapan ini dengan percobaan pendeteksian emosi tertentu pada aplikasi *game*.

Dalam penelitian ini masalah yang akan diteliti meliputi beberapa pertanyaan riset berikut:

- Bagaimana mengenali emosi-emosi tertentu dari suatu *player* dalam *game* berbasis sistem komputasi sesuai dengan kategori emosi yang telah ditetapkan
- Bagaimana membangun sistem komputasi yang dapat belajar (melalui tahapan *machine learning*) menggunakan metode Meta Learning dari kumpulan citra / *image* yang dikumpulkan sebagai data set percobaan untuk dapat mengenali emosi-emosi *player* sesuai rumusan masalah di atas

Bagaimana menilai tingkat keberhasilan dari sistem komputasi tersebut agar dapat ditentukan aksi selanjutnya dari sistem untuk menyesuaikan konten / tingkat kesulitan *game* agar meningkatkan *gaming experience* dari *player*

1.3. Tujuan Penelitian

Penelitian ini bertujuan untuk:

- Melakukan perancangan Sistem Pendeteksi Emosi pada Game berbasis metode Meta Learning yang meliputi tahapan:
 1. data *collection* untuk menyusun data set percobaan,
 2. melakukan proses pembelajaran / *learning* berbasis metode Meta Learning terhadap dataset yang terkumpul sehingga menghasilkan model yang dapat mengenali emosi *player* pada saat uji coba langsung,
 3. melakukan evaluasi tingkat akurasi,
 4. melakukan *re-tuning* proses *learning* sampai didapatkan model yang cukup baik dalam pengenalan emosi
- Mengimplementasikan prototipe sistem / perangkat lunak pendeteksi emosi pada *game* berbasis metode Meta Learning

1.4. Batasan Penelitian

Batasan Penelitian dari sisi metodologi pengambilan data untuk percobaan:

- Data citra yang dikumpulkan sebagai data set percobaan dibatasi untuk 3 kategori emosi yaitu *enjoy*, *boring* dan frustrasi
- Pengambilan data citra *player* ketika sedang bermain game menggunakan web camera dan bukan menggunakan *special high end camera*

1.5. Kaitan Penelitian dengan Road Map Penelitian Pribadi dan Road Map Penelitian Fakultas

Penelitian ini sesuai dengan Road Map Penelitian Pribadi para Peneliti yang mengusulkan proposal ini yaitu terkait dengan pengembangan aplikasi dan sistem komputasi berbasis *machine learning* pada domain multimedia atau aplikasi interaktif dimana 3 dari 4 peneliti memiliki roadmap di bidang *machine learning* dan kecerdasan buatan dan 1 peneliti memiliki roadmap di bidang pemanfaatan multimedia dan aplikasi interaktif.

Penelitian ini juga sesuai dengan Road Map Penelitian Fakultas Teknologi Industri yaitu Pengembangan Smart Product dan Services dengan fokus penelitian di bidang Data Science (DS) dan Teknologi Informasi dan Komunikasi (TIK) di mana prototipe sistem yang diusulkan dalam proposal ini termasuk *smart product* berbasis teknologi *data science* dan TIK. Penelitian ini juga sesuai dengan Road Map Program Studi Teknik Elektro, khususnya dari Kelompok Bidang Keilmuan / Laboratorium Sistem Komputer dalam naungan *Stream Smart Electronics, Automation and Wireless System*.

BAB 2. TINJAUAN PUSTAKA

2.1. Pengalaman Bermain (Gaming Experience)

Gaming adalah aktivitas yang dilakukan oleh semua orang dari berbagai kalangan mulai dari anak-anak, remaja, dan dewasa. Ada banyak tipe game yang dibuat diantaranya *game fighting*, *action*, *First Person Shooter* (FPS), *Role Playing Game* (RPG), dll. Di dalam suatu *game* terdapat beberapa hal yang harus diperhatikan, salah satunya adalah *gaming experience*. *Gaming experience* adalah *tool* yang dapat digunakan untuk mengevaluasi *game*. *Gaming experience* dapat dinilai dari emosi dan pikiran *player* yang dipengaruhi dari kondisi saat bermain *game*. Ada beberapa komponen dari *gaming experience*, diantaranya:


- Kecepatan koneksi Internet (pada *online game*)
- Performa *gaming tool*
- Konten *gaming*
- Aksesoris *gaming*

Sebagai seorang *game developer*, hal yang dapat dikembangkan dengan cepat adalah dengan mengubah konten untuk memperbaiki *game experience* seorang *player*.

Dalam pengembangan konten *game*, ada yang disebut dengan *game difficulty*. *Game difficulty* adalah tingkat kesulitan yang dialami oleh *player* saat bermain *game*. *Game difficulty* dapat mempengaruhi salah satu *game experience* yaitu emosi. Ada 3 emosi yang dapat diidentifikasi saat bermain *game* yaitu menikmati (*enjoy*), bosan (*boring*), dan frustrasi. Penelitian Koster [8] menunjukkan adanya korelasi antara *player skill* dan *game difficulty*.

- Jika *player skill* terlalu tinggi sementara *game difficulty* terlalu mudah (*easy*), maka *player* akan cenderung merasa bosan
- Jika *player skill* terlalu rendah sementara *game difficulty* terlalu sulit (*hard*), maka *player* akan cenderung merasa frustrasi

Adams [9] menggambarkan korelasi ini sesuai dengan gambar (2.1.1.).



Gambar 2.1.1. Korelasi *game difficulty* dan *player skills* terhadap *player enjoyment*

Untuk mendapatkan *game balancing* dibutuhkan hubungan yang sesuai antara *player skill* dan *game difficulty*. Oleh karena itu, dibutuhkan suatu sistem yang dapat mendeteksi emosi bosan, frustrasi, dan *enjoy*. Sistem ini bisa dimanfaatkan oleh *game developer* untuk mengoptimasi *game* mereka dengan cara mengotomasi *game level* berdasarkan emosi dari *player*.

2.2. Cara Medeteksi Ekspresi

Tujuan utama *game* adalah sebagai media *entertainment*, tetapi fokus utamanya adalah untuk menarik / menyita perhatian (*engage / engaging*) [10]. Salah satu teknik untuk mengatur *engagement* saat bermain *game* adalah dengan mengendalikan emosi player. Emosi bisa dihasilkan pada saat bermain *game*. Berdasarkan penelitian psikologi, ada beberapa pertimbangan untuk menganalisis emosi dalam konteks *game* [11].

- Emosi sebagai *side effect* dari permainan: Emosi secara keseluruhan tidak begitu penting. Tetapi yang penting adalah membuat *player enjoy* dan menjauhkan mereka dari frustrasi
- Emosi sebagai alat untuk *engage*: emosi sangat penting karena bisa mengendalikan *engagement* dari player

Dari hasil penelitian tersebut, kita dapat menyimpulkan bahwa pentingnya emosi dalam pengembangan sebuah *game*. Dengan catatan bahwa keberhasilan *game* dapat diukur dengan kemampuan *game* untuk menghasilkan emosi yang positif seperti *enjoy*. Dengan mengetahui pentingnya deteksi emosi dalam pengembangan sebuah *game*, langkah utama yang dapat kita lakukan yaitu dengan mendeteksi emosi player sehingga kedepannya kita dapat memberikan *feedback* untuk memperbaiki dan meningkatkan *gaming experience*.

Saat ini sudah banyak penelitian yang menyangkut pengklasifikasi emosi. Ada beberapa cara untuk menentukan emosi dilihat dari media yang digunakan. Penelitian Danisman dkk. [12] menilai emosi melalui text. Adapun cara yang digunakan adalah berbasis Vector Space Model (VSM). Cara VSM ini lebih unggul daripada ConceptNet, Naïve Bayes, dan Support Vector Machine. Adapun salah satu keunggulan metode ini adalah bisa mendeteksi emosi berdasarkan *subtitle text* dari sebuah video. Selanjutnya penelitian Yang dkk. [13] membahas mengenai emosi dari sebuah musik. Cara yang digunakan adalah menggunakan 2 *fuzzy classifier* untuk mengukur emosi musik. Nwe dkk. [14] meneliti emosi berdasarkan speech. Metode yang digunakan adalah Discrete Hidden Markov Model dan Mel *frequency short time speech power coefficients*.

Selain metode-metode sebelumnya, ada beberapa cara lain yang digunakan untuk mengukur emosi langsung dari manusia. Penelitian Li dkk. [15] menggunakan sinyal EEG untuk mengukur emosi senang dan sedih dilihat dari perilaku gelombang otak. Adapun metode yang digunakan adalah Common Spatial Pattern (CSP) dan linear-SVM untuk memproses sinyal EEG menjadi emosi.


Penelitian Pedersen dk. [16] menggunakan *feature statistical* seperti seberapa sering dan kapan player melompat, berlari, mati, dll. Dengan menggunakan metode ini, dapat diklasifikasikan emosi *challenge*, frustrasi, dan senang dengan akurasi 77.77%, 88.66%, dan 69.18%. Sementara itu Zeng [17] meneliti emosi dari Adult Attachment Interview (AAI) video. Dari video ini diperoleh *image* dengan emosi dan tanpa emosi. Dari penelitian yang dilakukan, diperoleh hasil akurasi maksimal menggunakan one-class K-means *Clustering* and *Score Based VDD / Vector Data Description* (KSVDD) dengan nilai 87% untuk *image* wanita.

Agrawal dkk. [18] menggunakan pendekatan *feature based*, dimana fitur wajah disegmentasi dan digunakan sebagai input untuk klasifikasi. Teknik yang digunakan adalah membandingkan *image* target dengan *image* ekspresi netral kemudian menggunakan algoritma Viola and Jones dengan Principal Component Analysis (PCA). Setelah itu diperoleh nilai Euclidean *distance* dan *mean error* untuk mendefinisikan apakah termasuk ekspresi netral, sedih, dan senang. [19] menggunakan multi-level deep representations (MldrNet) dengan memperhatikan *hand-crafted features* or *deep features* untuk mengklasifikasikan *image emotion*. *Image* yang digunakan berupa lukisan abstrak dan web *image*. Dengan cara tersebut mereka mendapatkan improvement 6% dibandingkan metode *the-state-of-art*. Metode terbaru digunakan oleh Zhou dkk. [20] yang menerapkan *few shot learning* untuk klasifikasi emosi dengan menggunakan general meta-training network (Meta-IEC).

2.3. Meta Learning

Meta learning adalah salah satu metode *learning* yang dapat melakukan *training* dengan cepat dan menggunakan data yang sedikit. Banyak cara untuk mengimplementasikan *meta learning* diantaranya *metric-based*, *model-based*, dan *optimization-based meta learning*.

Chelsea Finn [21] memperkenalkan salah satu cara *optimization-based meta-learning* yaitu Model-Agnostic Meta-Learning. Andreas Antonio [22] juga melakukan *improvement* terhadap algoritma MAML dengan beberapa cara seperti Multi-Step Loss dan Cosine Annealing pada *learning rate*. Metode *meta learning* dapat diilustrasikan pada gambar 2.3.1. di bawah ini.



Gambar 2.3.1. Ilustrasi metode Meta Learning

BAB 3. METODOLOGI PENELITIAN

3.1. Waktu dan Tempat Penelitian

Penelitian ini dimulai dengan penyusunan Proposal Penelitian sesuai arahan Dewan Riset dan Pengabdian Masyarakat Fakultas (DRPM-F) dari Fakultas Teknologi Industri (FTI) melalui Seleksi Internal pada tanggal 27-28 September 2021. Proposal Penelitian ini dinyatakan lolos seleksi internal untuk diusulkan melalui SIMPPM ke Lembaga Penelitian (Lemlit) Universitas Trisakti (Usakti) untuk *approval* dan pengesahan dari Lemlit Usakti.

Tahapan Penelitian ini dilanjutkan dengan persiapan pelaksanaan secara paralel dengan tahapan pengesahan agar dapat dimulai langsung begitu *approval* dan dana turun pada akhir Oktober 2021. Pelaksanaan direncanakan selama 8 bulan di Laboratorium dengan 1 bulan persiapan Luaran dan 1 bulan persiapan Laporan Akhir pada akhir Juli 2022. Penelitian meliputi pengumpulan data, pembangunan model *machine learning* menggunakan metode *meta learning*, *training* dan *testing* model serta *fine-tuning* diikuti dengan analisis dan pengambilan kesimpulan. Total pelaksanaan penelitian adalah 10 bulan (Oktober 2021 – Juli 2022).

Penelitian dilaksanakan dalam durasi 10 bulan, dimulai dari awal Oktober 2021 pada tahapan finalisasi proposal dan persiapan pelaksanaan. Penelitian dilanjutkan dengan percobaan di Laboratorium Sistem Komputer dari bulan November 2021 – Juni 2022 dan diakhiri oleh pelaporan luaran dan laporan akhir di bulan Juli 2022. Telah terjadi kendala disebabkan perubahan afiliasi Peneliti Utama sehingga diperlukan alternatif solusi sehingga Laporan baru dapat terselesaikan pada Semester Genap 2024/2025.

Tabel 3.1.1 Jadwal Kegiatan Penelitian

NO	Kegiatan	2021			2022						
		10	11	12	1	2	3	4	5	6	7
1	Studi pustaka										
2	Penyusunan proposal										
3	Pembuatan model										
4	Pengujian program										
5	Analisis Hasil										
6	Publikasi Jurnal										
7	Pembuatan Luaran HKI										

3.2. Metode Penelitian

3.2. 1. Proses Penelitian

Proses penelitian dimulai dari pengambilan data untuk *meta-training task*, yaitu gambar emosi dari N-player ketika sedang bermain *game*. Dimana N adalah jumlah *meta-training task*. Selanjutnya dilakukan juga *recording image user* yang akan menjadi *meta-testing task*. *Meta-training task* dan *meta-testing task* kemudian diimpor ke dalam Python code dan dilakukan *face detection* menggunakan algoritma *multitask convolutional neural network* (MTCNN). MTCNN disebut *multitask* karena menggunakan 3 task dengan menggunakan 3 model yang disusun secara *cascade*. Ketiga task itu digunakan untuk memprediksi *face classification*, *bounding box regression*, dan *facial landmark localization*. Dalam project ini, MTCNN digunakan untuk memperoleh *image* wajah player tanpa *background* sehingga dapat meningkatkan akurasi prediksi *meta-learning*. Setelah itu diperoleh *image* dan dilakukan *resize* agar sesuai dengan model *training* yang digunakan.


Langkah selanjutnya adalah membuat grup untuk *meta-training task* dan *meta-testing task*. Task pada *meta-training* dan *meta-testing* menggunakan data *player* yang berbeda. Hal ini disebabkan karena struktur wajah tiap *player* yang berbeda-beda. *Meta-learning* dipercaya dapat mengekstrak struktur general dari semua wajah sehingga hasil prediksinya akan lebih baik dibandingkan pendekatan *training from scratch*. Dalam hal ini *training from scratch* adalah pendekatan konvensional yang digunakan dengan membuat model *random* terlebih dahulu sebelum dilakukan *training* pada *task* yang spesifik. *Training from scratch* akan digunakan sebagai *benchmark* untuk evaluasi *meta-learning*.

Kemudian *meta-training task* akan ditraining pada proses *meta-training*. Pada proses ini, *meta-training* akan menghasilkan struktur general tiap *task* dengan mencari parameter model yang memiliki *loss* terkecil pada semua *task*. Parameter ini disebut sebagai *meta-training parameter*. *Meta-training parameter* akan digunakan untuk melatih *meta-testing task* dengan hanya menggunakan sedikit sample *training* dan sedikit *epoch*.


Untuk meningkatkan kualitas *meta-training parameter* ini, dilakukan beberapa modifikasi dengan membuat Multi-Step Loss dan Cosine Annealing pada *learning rate*. Setelah dilakukan *training* dengan menggunakan *meta-testing task*, diperoleh nilai akurasi untuk beberapa *image*. Nilai akurasi ini dalam bentuk persentase yaitu nilai prediksi yang benar terhadap keseluruhan sample prediksi. Semakin tinggi nilai akurasi, maka semakin baik model yang dibuat.

3.2.2. Diagram Alir Proses Pengenalan Emosi

Berikut adalah diagram alir untuk proses *gaming emotion recognition* menggunakan *meta-learning*.



Gambar 3.2.2.1 Diagram alir proses *gaming emotion recognition* menggunakan *meta-learning*



Gambar 3.2.2.2 Arsitektur Model *Machine Learning* berbasis metode *Meta Learning*


3.2.3. Spesifikasi Model *Machine Learning* berbasis metode *Meta Learning*

Model *training* menggunakan konvolusi 2D dan max pool 2D. Layer konvolusi digunakan untuk mengekstrak atribut gambar sedang layer *max pool* digunakan untuk mereduksi gambar resolusi gambar sehingga proses *training* bisa lebih cepat.

Berikut detail layer pada model yang digunakan:

- 2 Convolution 2D layers
 - 64 neurons
 - Kernel = (3,3)
 - Input shape = image size
- 2 Max pooling 2D layers
 - Pool size = (2,2)
- Dense layer
 - 512 neurons
- Output layer
 - Neuron = gaming emotion states = 3
- Flatten layer
- Dropout (Optional)

3.2.4. Proses Pengumpulan Data



Gambar 3.2.4.1 Infratraktur proses pengumpulan beserta pertukaran data yang terjadi

Beberapa *player* bermain sebuah *game*. *Player* akan menentukan salah satu level yang nyaman bagi *player*. Kemudian akan dilakukan *capturing* beberapa image untuk emosi *enjoy*. Setelah itu akan dilakukan peningkatan dan penurunan level sehingga memperoleh emosi *boring* dan *frustasi*. Setelah itu *image player* yang dikumpulkan akan dipindahkan ke dalam suatu direktori. *Image* ini akan digunakan dalam *training* dengan algoritma *gaming emotion recognition* menggunakan *meta-learning*.

3.3. Metode Analisis

Analisis terhadap keberhasilan suatu model machine learning dilakukan dengan metode uji standar yang meliputi pengukuran Akurasi yang meliputi 3 parameter yaitu Recall, Precision dan F1-Measure yang didapatkan dari *confusion matrix* seperti digambarkan pada Gambar 3.3.1 dengan rumusan seperti digambarkan pada Gambar 3.3.2.

		Predicted	
		Negative	Positive
Actual	Negative	True Negative	False Positive
	Positive	False Negative	True Positive

Gambar 3.3.1 *Confusion Matrix* pada hasil metode *Machine Learning*

$$\text{Precision} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Positive}}$$

$$\text{Recall} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Negative}}$$

$$\text{F1} = 2 \times \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}}$$

Gambar 3.3.2 *Precision, Recall dan F1-measure* untuk penilaian hasil metode *Machine Learning*

3.4. Indikator Capaian Penelitian

- Hasil penelitian ini akan menambah referensi literatur penelitian pendeteksian emosi pada aplikasi *game* menggunakan metode *machine learning* khususnya metode *meta learning* yang dapat dimanfaatkan tidak hanya di domain *gaming* namun dapat diterapkan juga di domain lain seperti pembelajaran interaktif atau pembelajaran berbasis *gamification*.
- Hasil penelitian ini akan menambah kapasitas personil dan sarana dalam lingkup Laboratorium / Kelompok Bidang Keilmuan Sistem Komputer di Program Studi Teknik Elektro dalam mengembangkan prototipe sistem berbasis Machine Learning, secara spesifik untuk meningkatkan evaluasi pembelajaran melalui penilaian ketertarikan peserta belajar dalam mengikuti modul interaktif. Prototipe sistem ini dapat terus dikembangkan untuk diaplikasikan dalam proses pembelajaran di Prodi, Fakultas maupun Universitas.
- Hasil penelitian ini akan menambah referensi literatur penelitian institusi perguruan tinggi di Indonesia di bidang machine learning / meta learning. Selain itu prototipe yang dihasilkan pada Tingkat kesiapterapan Teknologi (TkT 3) dapat terus dikembangkan menjadi sistem yang lebih siap untuk diaplikasikan dalam proses pembelajaran yang lebih luas di luar Institusi pengembang dengan meningkatkan tingkat kesiapterapan teknologi ke tingkatan lebih tinggi.

BAB 4. HASIL DAN PEMBAHASAN

1. Pelaksanaan Kegiatan Penelitian

Kegiatan Penelitian dilaksanakan dengan terlebih dahulu melakukan rekrutmen Tim Peneliti Pelaksana dari Mahasiswa yang telah dan sedang menempuh Mata Kuliah Machine Learning di KMK Sistem Komputer, Stream Smart Network dan Industrial Automation yaitu 3 mahasiswa sebagai berikut:

1. Rafly Ramandani (NIM: 062001700027)
2. Handika Budi Utama (NIM: 062001700005)
3. Arya Anila Vyasa (NIM: 062002100010)

Tim yang terdiri dari Tim Peneliti Dosen melaksanakan Diskusi Mingguan setiap hari Selasa dan kemudian disesuaikan jadwalnya menjadi hari Rabu dengan agenda Bimbingan dan Pengarahan serta Laporan Kemajuan dan Kendala dalam pelaksanaan teknis.

Laporan Pelaksanaan Kegiatan secara terperinci adalah sesuai tahapan yang akan dijelaskan pada bagian 4.3 Laporan ini.

2. Keterlibatan Mahasiswa di dalam Kegiatan Penelitian

Keterlibatan Mahasiswa di dalam Penelitian ini adalah sebagai Pelaksana Teknis terutama dalam melakukan eksplorasi teknis seperti eksplorasi metode implementasi terutama yang menyangkut pemrograman serta pelaksanaan percobaan yang meliputi eksplorasi data set, pengumpulan data set untuk percobaan, proses pelatihan berbasis data set serta proses pengujian berbasis data set.

Manfaat yang diharapkan didapat oleh Mahasiswa adalah dapat menerapkan Teknik-teknik yang telah dipelajari di Mata Kuliah dan juga mendapatkan wawasan riset untuk pengembangan ilmu lebih lanjut terutama *state of the art* metode-metode *machine learning* terbaru.

3. Laporan Hasil Sesuai Tahapan Penelitian

Tahapan Laporan Kemajuan


Penelitian “Gaming Emotion Recognition Menggunakan Meta Learning” melalui beberapa proses untuk dapat berjalan. Selama proses penelitian, ada beberapa kegiatan yang sudah terlaksana dan ada beberapa juga yang belum terlaksana. Rapat penelitian dilakukan setiap minggunya untuk melihat progress dari pelaksanaan penelitian ini. Adapun laporan hasil penelitian dapat dilihat pada poin-poin dibawah ini:

Kegiatan yang sudah Terlaksana


1. Eksplorasi dataset untuk Uji coba Metode *Face Detection*
Semakin *representative* dataset yang digunakan, maka performance *machine learning* akan semakin bagus. Sehingga penting dalam penelitian untuk memperoleh dataset yang focus. Sebagai langkah awal, penelitian dapat menggunakan dataset dari internet seperti JAFFE, CK+, AffectNet, dan Deepface. Pada penelitian ini, kami memutuskan untuk menggunakan dataset dari *deepface* yang memiliki 61 image tokoh public dengan jarak yang berbeda. Dengan pemilihan *image* ini, diharapkan proses *face detection* menjadi lebih stabil untuk image yang akan dikumpulkan secara langsung. Image yang akan dikumpulkan divariasikan menggunakan wajah orang yang berbeda dengan 3 ekspresi *enjoy*, *frustasi*, dan *bosan*.



Gambar 4.3.1 Dataset CK+



Gambar 4.3.2. Dataset JAFFE



Gambar 4.3.3 Dataset Affectnet



Gambar 4.3.4 Dataset Deepface


2. Uji coba dan Komparasi Metode *Face Detection*

Image RAW pada setiap dataset memiliki banyak informasi. Agar dapat *focus* terhadap emosi dari wajah, maka perlu dilakukan *face detection* terlebih dahulu. Setelah mendapatkan *image* wajah dengan ukuran yang besar maka kita dapat mempertajam kontras informasi emosi yang dibutuhkan.

Pada penelitian yang telah dilakukan, kami mencoba 2 algoritma *face detection* yaitu Multi-task Cascaded Convolutional Networks (MTCNN) dan RetinaFace. Adapun pertimbangan memilih algoritma adalah akurasi pendeteksian wajah, kecepatan pemrosesan, dan fleksibilitas ukuran wajah

yang dideteksi. Berdasarkan paper [23], MTCNN yang merupakan algoritma *face detection* dengan *deep learning* mampu menghasilkan performa yang lebih baik dibandingkan *state-of-the-art method* (penelitian sebelumnya) untuk dataset Face Detection Data Set and Benchmark (FDDB) dan WIDER FACE sebagai benchmark. RetinaFace merupakan algoritma *face detection* yang menggunakan *deep learning*. RetinaFace mampu mendeteksi wajah dengan mengumpulkan informasi *landmark* seperti mata kiri, mata kanan, hidung, mulut kiri, dan mulut kanan. Penelitian [24] menunjukkan bahwa RetinaFace mampu menghasilkan nilai presisi 91.4% yaitu lebih tinggi dibandingkan metode Improved Selective Refinement Network yang hanya memperoleh nilai presisi 90.3%.

Hasil penelitian menggunakan dataset deepface menunjukkan bahwa MTCNN dan RetinaFace mampu mendeteksi semua wajah. RetinaFace memiliki keuntungan dengan pemrosesan yang lebih cepat antara 0.4-3.2 detik sedangkan MTCNN membutuhkan waktu 1-4 detik. Akan tetapi MTCNN dilengkapi dengan fitur *resize* pada pendeteksian sehingga dapat menentukan ukuran *pixel* pada *face detection* yang dihasilkan.



Gambar 4.3.5 Hasil ekstrak 5 informasi landmark pada RetinaFace

3. Pembelajaran Konsep *Meta Learning* oleh Anggota Pelaksana (Mahasiswa)


Pembelajaran Konsep *Meta Learning* telah dilakukan kepada anggota pelaksana penelitian. Adapun pembelajaran yang dilakukan adalah dengan membahas paper [1] oleh Chelsea Finn yang mempopulerkan ide *Meta Learning*. Dalam proses pembelajaran ini juga diberikan sumber bacaan berupa paper dan website terkait *Meta Learning*.

- Chelsea Finn [21]: mengenai konsep dasar *Meta Learning* dan *Model-Agnostic Meta-Learning* (MAML)
- Chelsea Finn [25]: mengenai online *Meta Learning*
- Yoon Jaesik [26]: mengenai Bayesian *Model-Agnostic Meta-Learning*
- Alex Nichol [27]: mengenai 1st Order MAML
- Antreas Antoniou [22]: mengenai optimasi MAML
- <https://machinelearningmastery.com/> dan <https://www.analyticsvidhya.com/> : sebagai materi tambahan konsep dan *coding*

Kegiatan yang direncanakan selanjutnya

4. Pemrosesan Image dan Pembentukan Struktur Dataset
Langkah selanjutnya dari penelitian ini adalah Pemrosesan *Image*. Pemrosesan *image* dilakukan untuk mendukung model *training* sebelum dilakukan proses *training*. Pemrosesan ini terdiri dari proses pengubahan menjadi *grayscale*, dan proses filter *histogram equalization*. Proses perubahan *grayscale* bertujuan agar informasi yang diproses tidak terlalu besar. Hal ini disebabkan image RGB memiliki informasi 3 kali lipat lebih besar dibandingkan *image grayscale*. Sedangkan filter *histogram equalization* bertujuan untuk meningkatkan kontras image.

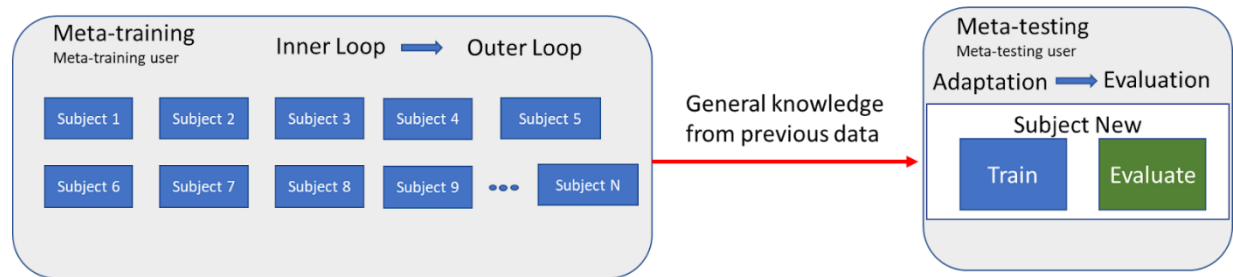
Setelah image diproses, dapat dilakukan proses pembentukan struktur dataset. Pembentukan struktur dataset bertujuan untuk mempermudah akses dataset sebelum diproses. Berikut adalah gambar struktur direktori dataset yang dirancang.



Gambar 4.3.6 Struktur Direktori Dataset

Untuk membuat dataset lebih banyak dapat digunakan *ImageDataGenerator* yang dapat melakukan transformasi gambar dengan cara rotasi, *shifting* kolom, *shifting* baris, *zoom*, serta *horizontal flip*.

5. Pengumpulan Dataset dan Pemisahan (Split) untuk *Meta Training* dan *Meta Testing*
Setelah ada pemrosesan image dan pembentukan struktur dataset yang jelas, penelitian dapat dilanjutkan dengan pengumpulan dataset. Pengumpulan dataset dibedakan untuk bagian meta training dan meta testing. Sebagian besar subject akan diproses pada meta-training, sedangkan subject baru akan diproses meta-testing dan dilakukan evaluasi.



Gambar 4.3.7 Proses Pengolahan Data Meta-Training dan Meta-Testing

6. Siklus Percobaan
 - a. Proses Meta Training

Proses ini merupakan bagian dari *pre-training* yang bertujuan untuk mendapatkan *general knowledge* dari beberapa *image subject*. Pada saat *meta-training*, subject 1, 2, dan seterusnya diproses secara individual dan menghasilkan *loss* masing-masing. *Loss* ini digunakan untuk mendapatkan *adapted parameter* yang merupakan parameter terbaik untuk memodelkan masing-masing *subject*, proses ini disebut dengan *inner loop*. Setelah itu proses berlanjut ke *outer loop*. Proses ini akan menghitung parameter baru yang memberikan *error* paling minimum untuk semua *subject*. Parameter baru ini dapat disebut juga dengan *general knowledge*. Hal ini memungkinkan meta learning untuk beradaptasi dengan cepat.
 - b. Proses Meta Testing

Proses meta-testing merupakan lanjutan dari *meta-training*. Meta-testing memanfaatkan *general knowledge* untuk dapat melakukan *training* pada *subject* baru dengan *sample* yang sedikit dan *training step* yang sedikit.
7. Analisis Hasil Percobaan

Percobaan evaluasi akan dilakukan dengan memilih 1 *subject* sebagai *subject* di *meta-testing* sedangkan *subject* yang lain akan berperan sebagai *subject* di *meta-training*. *Subject* di *meta-testing* akan dipilih secara bergantian. Setelah itu, hasil akurasi *meta-learning* akan dibandingkan dengan hasil konvensional *training*.

Tahapan Laporan Akhir

8. Telah dilakukan ujicoba model awal untuk mendeteksi emosi pemain melalui ekspresi wajah menggunakan metode Convolutional Neural Network yang memberikan hasil akurasi lebih baik jika dibandingkan dengan metode PyTorch. Hasil ujicoba ini telah dilakukan oleh anggota Tim dalam rangka Studi Lanjut Tingkat Magiste. Judul luaran artikel yang dihasilkan sebagai berikut: "Emotional Classification Based on Facial Expression Recognition Using Convolutional Neural Network Method" yang dipublikasikan dalam Asian Journal of Social and Humanities: Vol. 1 No. 12 (2023).
9. Telah disusun beberapa draft artikel untuk memberikan pemahaman lebih lengkap terhadap state of the art eksperimen yang telah dilakukan dan juga melaporkan hasil ujicoba lebih lanjut. Draft terlampir.
10. Telah dilakukan studi terhadap ketersediaan dataset public yang dapat digunakan untuk memverifikasi lebih lanjut hasil uji coba model awal yang akan dilaksanakan pada tahapan penelitian selanjutnya, dikarenakan keterbatasan sumber daya pelaksana peneliti dan waktu.

Terdapat kumpulan data publik yang sangat cocok untuk eksperimen Pengenalan Emosi dalam Permainan menggunakan model meta-pembelajaran seperti MAML. Persyaratan utama untuk pengaturan semacam itu adalah kumpulan data yang berisi data dari beberapa individu, yang memungkinkan setiap orang diperlakukan sebagai "tugas" terpisah untuk dipelajari oleh algoritma meta-pembelajaran. Berikut adalah beberapa kumpulan data publik yang paling sesuai:

1. GAMEEMO: Basis Data untuk Sistem Pengenalan Emosi 🧠

Kumpulan data ini berisi sinyal EEG dari 28 subjek berbeda saat mereka bermain gim yang dirancang untuk memunculkan empat keadaan emosi yang berbeda (membosankan, tenang, horor, dan lucu). Struktur ini sempurna untuk pendekatan berbasis MAML di mana tujuan modelnya adalah untuk "belajar cara belajar" dari individu yang berbeda. Anda dapat memperlakukan masing-masing dari 28 subjek sebagai tugas terpisah, melatih meta-model untuk cepat beradaptasi dengan pemain baru yang belum pernah dilihat sebelumnya hanya dengan beberapa sampel. Modalitas: Data EEG 14 kanal. Label: Penilaian emosi yang dilaporkan sendiri dan formulir SAM (Manikin Penilaian Diri) tersedia untuk setiap subjek.

2. AMuCS: Set Data Counter-Strike Multimodal Afektif 🎮

Dataset ini sangat baik untuk mengeksplorasi pengenalan emosi multimodal dalam lingkungan permainan yang lebih alami dan kompetitif. AMuCS menampilkan data dari 256 peserta yang bermain Counter-Strike: Global Offensive di acara LAN. Jumlah peserta yang besar menyediakan sumber "tugas" yang beragam untuk meta-pembelajaran, memungkinkan pelatihan model yang kuat yang dapat digeneralisasikan ke pemain baru.

Modalitas: Ini adalah kumpulan data yang sangat kaya, termasuk: Sinyal fisiologis (EKG, EDA, Respirasi) Sinyal perilaku (ekspresi wajah, pelacakan mata) Data interaksi komputer (peristiwa keyboard/mouse, aksi permainan) Video dan log permainan Label: Anotasi yang dilaporkan sendiri tentang gairah dan valensi tersedia.

3. Dataset Relevan Lainnya (Tidak Khusus untuk Game, tetapi Digunakan untuk Pengenalan Emosi Few-Shot)

Meskipun set data di bawah ini tidak berfokus pada game, set data tersebut telah berhasil digunakan dalam penelitian pengenalan emosi few-shot dan dapat diadaptasi untuk studi percontohan. Set data ini berguna jika Anda ingin menguji model pada stimulus pemicu emosi yang lebih tradisional sebelum beralih ke data game yang kompleks.

- DEAP (Database untuk Analisis Emosi menggunakan Sinyal Fisiologis): Berisi EEG dan sinyal fisiologis perifer dari 32 peserta yang menonton 40 video musik berdurasi satu menit. Jumlah peserta yang besar membuatnya cocok untuk menyiapkan tugas MAML.
- AMIGOS (Set data untuk penelitian multimodal tentang afek, ciri kepribadian, dan suasana hati pada Individu dan Kelompok): Meliputi data fisiologis (EEG, EKG, GSR) dan video dari 40 peserta dalam pengaturan individu dan kelompok sambil menonton klip video pendek. Keragaman subjeknya merupakan aset utama untuk meta-pembelajaran.

11. Telah dilakukan studi terhadap ketersediaan model pralatih yang dapat digunakan untuk memverifikasi lebih lanjut hasil uji coba model awal yang akan dilaksanakan pada tahapan penelitian selanjutnya, dikarenakan keterbatasan sumber daya pelaksana peneliti dan waktu. Hingga akhir tahun 2025, model AI pra-latih yang tersedia untuk umum dan menggunakan Meta-Learning (MAML) khusus untuk mengklasifikasikan emosi pemain game hanya berdasarkan ekspresi wajah belum tersedia sebagai alat siap pakai yang dapat diunduh. Meskipun konsep ini merupakan bidang penelitian akademis yang sangat aktif dan

menjanjikan, model-model ini belum diproduksi dan dirilis ke komunitas sumber terbuka dalam format yang ramah pengguna.

Status Penelitian vs. Alat yang Tersedia

Penelitian Akademis Aktif: Ada banyak makalah penelitian yang mengeksplorasi penggunaan MAML dan teknik meta-pembelajaran lainnya untuk pengenalan emosi. Ide intinya adalah untuk memecahkan "masalah personalisasi"—model pengenalan emosi wajah (FER) standar mungkin tidak memahami cara spesifik Anda mengekspresikan frustrasi, tetapi model berbasis MAML dapat mempelajarinya dari beberapa contoh. Para peneliti telah menerbitkan makalah yang menunjukkan bahwa pendekatan ini bekerja dengan baik, seringkali mencapai akurasi yang lebih tinggi daripada model umum.

Kurangnya Model Publik: Kendala utama dalam menemukan model pra-latih adalah:

- **Spesifisitas Set Data:** Model-model ini sangat bergantung pada set data tempat mereka dilatih. Model yang dilatih secara meta pada set data gim tertentu yang dikontrol lab (seperti GAMEEMO atau AMuCS, yang seringkali mencakup lebih dari sekadar video) mungkin tidak berkinerja baik "di alam liar".
- **Kompleksitas Implementasi:** MAML lebih kompleks untuk diimplementasikan dan dilatih daripada model pembelajaran mendalam standar. Para peneliti sering kali mempublikasikan kode mereka di platform seperti GitHub, tetapi ini biasanya merupakan basis kode penelitian—bukan API atau pustaka yang siap produksi. Mereka membutuhkan keahlian yang signifikan untuk diadaptasi dan digunakan.
- **Kelayakan Komersial:** Perusahaan yang mengembangkan teknologi ini (seperti yang bergerak di bidang komputasi afektif atau pengujian pengalaman pengguna) akan menganggap model-model ini sebagai aset kepemilikan yang berharga dan kecil kemungkinannya untuk merilisnya ke publik.

Jalur Alternatif.

Meskipun Peneliti tidak dapat mengunduh "MAML Gamer Emotion Classifier" yang sudah tersedia, Peneliti dapat mengembangkannya menggunakan sumber daya yang tersedia yaitu:

- **Memulai dengan Model FER Umum yang Telah Dilatih Sebelumnya** serta menggunakan model Pengenalan Emosi Wajah sumber terbuka yang canggih seperti yang berbasis arsitektur seperti ResNet, VGG-Face, atau Vision Transformers. Model-model ini dapat mengklasifikasikan emosi dasar (senang, sedih, marah, netral, terkejut, takut) secara langsung. Meskipun tidak spesifik untuk bermain game, emosi seperti "marah" sering kali berkorelasi dengan "frustrasi," dan "netral" dapat berkorelasi dengan "fokus." Ini memberikan dasar yang kuat.
- **Menyempurnakan Model FER Standar pada Data Game:** menemukan atau membuat kumpulan data ekspresi wajah gamer. Peneliti dapat menggunakan set data publik seperti AFEW (Acted Facial Expressions in the Wild) atau merekam data secara mandiri. Ini akan mengadaptasi pemahaman model tentang emosi dengan nuansa konteks game.
- **Implementasi MAML Sendiri (Rute Lanjutan):** Eksplorasi repositori GitHub yang terkait dengan makalah akademis tentang "MAML untuk Pengenalan Emosi Wajah." Hal ini dapat dilakukan di situs seperti Papers with Code. **Adaptasi Kode:** Peneliti perlu mengadaptasi kode mereka agar berfungsi dengan set data ekspresi wajah yang relevan dengan game. Ini membutuhkan pemahaman yang kuat tentang PyTorch atau TensorFlow, serta algoritma MAML itu sendiri. **Peneliti dapat melakukan training dari Awal:** Ini adalah proses

komputasi intensif yang membutuhkan set data yang sesuai dengan banyak individu berbeda untuk dijadikan "tugas" untuk meta-pelatihan.

Tabel 4.3.1 Ringkasan Jalur Alternatif Metode Pengembangan Selanjutnya

Approach	Pros	Cons	Availability
Use a Pre-trained MAML Gamer Model	Ideal, tailored for the task, requires little data per new user.	Does not currently exist as a public tool.	Very Low
Use a General Pre-trained FER Model	Easy to implement, many available models (e.g., DeepFace), good baseline.	Not specific to gaming context, not personalized.	High
Fine-Tune a Standard FER Model	More accurate for gaming than a general model.	Requires a labeled gaming-specific dataset.	Medium (Model is available, data needs work)
Implement MAML from Research Code	Most powerful and flexible approach, achieves personalization.	Very complex, requires deep learning expertise, computationally expensive.	Low (Code exists, but not as a ready tool)

BAB 5. KESIMPULAN DAN SARAN

Berdasarkan pelaksanaan penelitian awal dan juga kemajuan hasil yang diperoleh dapat disimpulkan bahwa:

- Proses eksplorasi data set untuk penentuan metode pendeteksian wajah telah dapat memberikan arah metode pendeteksian wajah yaitu MTCNN dan Retina Face (keduanya berbasis metode Deep Learning)
- Ujicoba model awal untuk mendeteksi emosi pemain melalui ekspresi wajah menggunakan metode Convolutional Neural Network yang memberikan hasil akurasi lebih baik jika dibandingkan dengan metode PyTorch
- Proses pembelajaran bagi tim mahasiswa khususnya untuk konsep baru metode pembelajaran Meta Learning cukup membutuhkan waktu dan penjelasan cukup mendalam dari Tim Dosen dikarenakan Meta Learning merupakan *state of the art learning method* dalam *Machine Learning*
- Masih diperlukan banyak waktu untuk menyelesaikan Penelitian ini terutama dari sisi pembelajaran dan percobaan walaupun tahapan yang perlu dilakukan sudah diketahui dengan lengkap

DAFTAR PUSTAKA

1. <https://www.indonesia.go.id/narasi/indonesia-dalam-angka/ekonomi/indonesia-siap-menuju-industri-4-0>
2. <https://www2.investindonesia.go.id/en/why-invest/indonesia-economic-update/making-indonesia-4.0-indonesias-strategy-to-enter-the-4th-generation-of-ind>
3. <https://lpmpjatim.kemdikbud.go.id/site/detailpost/revolusi-industri-4-0-untuk-pendidikan-di-indonesia>
4. <https://binus.ac.id/knowledge/2019/09/tren-dan-tips-gamifikasi-untuk-pembelajaran-online/#:~:text=Gamifikasi%20merupakan%20penggunaan%20prinsip-prinsip%20dan%20elemen%20utama%20pada,Dari%20segi%20pembelajaran%20C%20desain%20permainan%20seperti%20video%20>
5. <https://informatics.uui.ac.id/2021/04/24/gamifikasi-untuk-pendidikan-di-masa-depan-bagaimana-bisa/>
6. Ilaria Caponetto, Jeffrey Earp, Michela Ott, Gamification and Education: A Literature Review, Proceedings of the 8th European Conference on Games Based Learning, 2014
7. Jenni Majuria, Jonna Koivistoa, Juho Hamaria, Gamification of education and learning: A review of empirical literature, Proceedings of the 2nd International GamiFIN Conference (GamiFIN 2018) pp. 11-19, 2018
8. Koster, R.: Theory of Fun for Game Design. Paraglyph Press, Phoenix (2004)
9. Adams, E., Rollings, A.: Game Design and Development; Fundamentals of Game Design. Pearson Education, NJ (2007)
10. Michele D Dickey. Engaging by design: How engagement strategies in popular computer and video games can inform instructional design. Educational Technology Research and Development, 53(2):67{83, 2005
11. Eva Hudlicka. Affective computing for game design. In Proceedings of the 4th Intl. North American Conference on Intelligent Games and Simulation, pages 5{12, 2008.
12. Danisman, Taner, and Adil Alpkocak. "Feeler: Emotion classification of text using vector space model." AISB 2008 convention communication, interaction and social intelligence. Vol. 1. 2008.
13. Yang, Yi-Hsuan, Chia-Chu Liu, and Homer H. Chen. "Music emotion classification: A fuzzy approach." Proceedings of the 14th ACM international conference on Multimedia. 2006.
14. Nwe, Tin Lay, Foo Say Wei, and Liyanage C. De Silva. "Speech based emotion classification." Proceedings of IEEE Region 10 International Conference on Electrical and Electronic Technology. TENCON 2001 (Cat. No. 01CH37239). Vol. 1. IEEE, 2001.
15. Li, Mu, and Bao-Liang Lu. "Emotion classification based on gamma-band EEG." 2009 Annual International Conference of the IEEE Engineering in medicine and biology society. IEEE, 2009.
16. Pedersen, Chris, Julian Togelius, and Georgios N. Yannakakis. "Modeling player experience in super mario bros." 2009 IEEE Symposium on Computational Intelligence and Games. IEEE, 2009.
17. Zeng, Zhihong, et al. "Spontaneous emotional facial expression detection." J. Multim. 1.5 (2006): 1-8.
18. Agrawal, Samiksha, and Pallavi Khatri. "Facial expression detection techniques: based on Viola and Jones algorithm and principal component analysis." 2015 Fifth International Conference on Advanced Computing & Communication Technologies. IEEE, 2015.

19. Rao, Tianrong, Xiaoxu Li, and Min Xu. "Learning multi-level deep representations for image emotion classification." *Neural Processing Letters* 51.3 (2020): 2043-2061.
20. Zhou, Fan, et al. "Learning meta-knowledge for few-shot image emotion recognition." *Expert Systems with Applications* 168 (2021): 114274.
21. Chelsea Finn, Pieter Abbeel, and Sergey Levine. Model-agnostic meta-learning for fast adaptation of deep networks. In *Proceedings of the 34th International Conference on Machine Learning-Volume 70*, pages 1126{1135. JMLR. org, 2017.
22. Antreas Antoniou, Harrison Edwards, and Amos Storkey. How to train your maml. *arXiv preprint arXiv:1810.09502*, 2018.
23. Zhang, Kaipeng, et al. "Joint face detection and alignment using multitask cascaded convolutional networks." *IEEE signal processing letters* 23.10 (2016): 1499-1503.
24. Deng, Jiankang, et al. "Retinaface: Single-shot multi-level face localisation in the wild." *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2020.
25. Finn, Chelsea, et al. "Online meta-learning." *International Conference on Machine Learning*. PMLR, 2019.
26. Yoon, Jaesik, et al. "Bayesian model-agnostic meta-learning." *Advances in neural information processing systems* 31 (2018).
27. Nichol, Alex, Joshua Achiam, and John Schulman. "On first-order meta-learning algorithms." *arXiv preprint arXiv:1803.02999* (2018).

...

LAMPIRAN 1. ROAD MAP PENELITIAN



Simulating and evaluating an adaptive and integrated traffic lights control system for smart city application

2018

Penelitian ini menampilkan perancangan adaptive traffic lights control system sebagai bagian dari smart system untuk optimasi pemanfaatan jalan dan mengurangi kemacetan.

Menambahkan kemampuan monitoring suhu dan pengaturan fungsi pendinginan serta location tracking dari kontainer pembawa sampel virus Covid19 di daerah terpencil di Indonesia

2020

Smart Container Design for Transporting Virus Sample in Remote Areas

Joint Research dengan Tim Teknik Elektro dan Fakultas Kedokteran

Gaming Emotion

Recognition

Menggunakan Meta-Learning

2022

Memfaatkan salah satu metode machine learning yaitu meta-learning untuk memprediksi 3 emosi saat bermain seperti enjoy, boring, dan frustrasi. Untuk mengoptimalkan hasil prediksi, digunakan face detection dan optimasi parameter pada meta-learning

Memfaatkan metode machine learning di bidang Object Detection, Face Recognition, Activity Recognition untuk aplikasi pendeteksian pelanggaran lalu lintas contohnya: melawan arus dan pelanggaran lainnya

2024

Machine Learning Methods for Identification of Traffic Violation

Joint Research dengan Tim Teknik Elektro

Machine Learning Prediction for Servical Cancer

Joint Research dengan Tim Teknik Informatika dan TIm Fakultas Kedokteran

2026

Memfaatkan metode machine learning dengan penerapan sensor electric nose untuk pendeteksian kanker serviks secara non invasif

PETA JALAN PENELITIAN ENDANG DJUANA



Motion Prediction in Virtual Reality System

2018

Membuat prediksi gerakan player pada system virtual reality. Sistem mencakup logger untuk IMU dan EMG data. Persiapan dan pengolahan input, serta training dengan menggunakan neural network

Menggunakan meta-learning salah satu metode untuk training dengan menggunakan sedikit sample dan sedikit epoch untuk memprediksi pergerakan pemain saat menggunakan virtual reality

2020

Predictive Head Tracking via Meta Learning

Gaming Emotion Recognition Menggunakan Meta-Learning

2021

Memfaatkan salah satu metode machine learning yaitu meta-learning untuk memprediksi 3 emosi saat bermain seperti enjoy, boring, dan frustrasi. Untuk mengoptimalkan hasil prediksi, digunakan face detection dan optimasi parameter pada meta-learning

Machine learning digunakan untuk memprediksi gejala-gejala pada penderita penyakit seperti diabetes, kanker, dll. Hal ini bertujuan untuk mendeteksi lebih dini penyakit sehingga bisa ditangani lebih awal

2022

Implementasi Machine Learning Untuk Memprediksi Kasus dibidang Kesehatan

Penggunaan Machine Learning untuk IoT Project yaitu Mendeteksi Tipe Devais

2024

Device yang berhubungan dengan internet ada berbagai macam seperti HP, Laptop, Perangkat IoT, dll. IoT menggunakan system yang spesifik. Untuk melakukan hal seperti itu, dibutuhkan system yang bisa mengklasifikasi tipe devais yang terhubung

Banyak fraud yang terjadi didunia perbankan dan pembayaran melalui online. Dengan memanfaatkan behaviour dari pelanggan, machine learning bisa memutuskan apakah terjadi fraud atau tidak

2026

Fraud Analysis

Analisis Produk Asuransi Dengan Machine Learning

2028

Produk asuransi sangat banyak berada di masyarakat. Akan tetapi masyarakat masih sulit menentukan yang terbaik sedangkan perusahaan asuransi juga masih belum optimal untuk menyediakan produk yang sesuai. Dengan adanya machine learning, diharapkan dapat membuat permodelan yang bisa membantu memecahkan masalah ini

PETA JALAN PENELITIAN WAHYU FADLI SATRYA



Perancangan dan Implementasi Filter Digital Finite Impulse Response(FIR) dengan menggunakan DSKTMS320C6713


Joint Research dengan Tim Teknik Elektro

Penelitian ini menampilkan perancangan adaptive traffic lights control system sebagai bagian dari smart system untuk optimasi pemanfaatan jalan dan mengurangi kemacetan.

Dampak Pandemi Covid-19 terhadap Efektifitas E-Learning Di Labuan Bajo Sebagai Destinasi Pariwisata Super Premium

Memanfaatkan salah satu metode machine learning yaitu meta-learning untuk memprediksi 3 emosi saat bermain seperti enjoy, boring, dan frustrasi. Untuk mengoptimalkan hasil prediksi, digunakan face detection dan optimasi parameter pada meta-learning

Analisis Terhadap Quality of Service jaringan 5G Untuk Kegiatan UMKM & Industri Pariwisata di Daerah Destinasi Wisata Super Premium



ROADMAP PENELITIAN – RICHARD A. RAMBUNG



Simulating and evaluating an adaptive and integrated traffic lights control system for smart city application

2018
Penelitian ini menampilkan perancangan adaptive traffic lights control system sebagai bagian dari smart system untuk optimasi pemanfaatan jalan dan mengurangi kemacetan.

Sistem lampu lalu lintas waktu konstan umumnya tidak mampu menangani kemacetan yang pada akhirnya membuat ambulans sulit untuk diprioritaskan. Penelitian ini bertujuan untuk memberikan durasi lampu hijau sesuai prioritas dengan menggunakan sensor kamera.

Gaming Emotion Recognition Menggunakan Meta-Learning


2022
Memanfaatkan salah satu metode machine learning yaitu meta-learning untuk memprediksi 3 emosi saat bermain seperti enjoy, boring, dan frustrasi. Untuk mengoptimalkan hasil prediksi, digunakan face detection dan optimasi parameter pada meta-learning

Meneliti aplikasi Sistem Internet of Things (IoT) pada aplikasi agrikultur dan smart city dengan dukungan platform Big Data. Menerapkan metode Kecerdasan Buatan pada repository big data untuk analisis dan prediksi

Implementasi Internet of Things (IoT) dan Platform Big Data berbasis Kecerdasan Buatan

Implementasi Sistem Keamanan pada Sistem IoT berbasis Machine Learning

2026
Sistem IoT memiliki potensi sekaligus bahaya terkait privacy dan security. Bagaimana mengamankan sistem IoT dengan memanfaatkan metode machine learning akan diteliti



PETA JALAN PENELITIAN FERRIANTO GOZALI

LAMPIRAN 2. LUARAN PENELITIAN

LUARAN 1 :

Kategori Luaran : Hak Kekayaan Intelektual

Status : Tercatat/Tersedia

Jenis HKI : Hak Cipta

Nama HKI : Poster Penelitian - Gaming Emotion Recognition Menggunakan Meta-Learning

No. Pendaftaran : EC002024202637

Tanggal Pendaftaran : 2024-10-09

No. Pencatatan : 000775069

Penulis (Tim Peneliti) :

1. Tjhwa Endang Djuana, S.T., M.Eng., Ph.D.
2. Richard Antonius Rambung, S.T., M.T.
3. Wahyu Fadli Satrya, S.T., M.Sc.
4. Ir. Ferrianto Gozali, MSCS., IPM

LUARAN 2 :

Kategori Luaran : Hak Kekayaan Intelektual

Status : Tercatat/Tersedia

Jenis HKI : Hak Cipta

Nama HKI : Poster Penelitian - Gaming Emotion Recognition Menggunakan Meta-Learning

No. Pendaftaran : EC002024202637

Tanggal Pendaftaran : 2024-10-09

No. Pencatatan : 000775069

Penulis (Tim Peneliti) :

1. Tjhwa Endang Djuana, S.T., M.Eng., Ph.D.
2. Richard Antonius Rambung, S.T., M.T.
3. Wahyu Fadli Satrya, S.T., M.Sc.
4. Ir. Ferrianto Gozali, MSCS., IPM

LUARAN 3 :

Kategori Luaran : Artikel Ilmiah

Status : Submitted

Jenis Publikasi Jurnal : Jurnal Nasional Terakreditasi

Nama Jurnal : Intelmatics Journal

ISSN :

EISSN : 27758850

Lembaga Pengindek : SINTA

Url Jurnal : <https://e-journal.trisakti.ac.id/index.php/intelmatics/>

Judul Artikel : Gaming Emotion Recognition with Model-Agnostic Meta-Learning on Facial Expression Data

Penulis (Tim Peneliti) :

1. Tjhwa Endang Djuana, S.T., M.Eng., Ph.D. (First Author)
2. Wahyu Fadli Satrya, S.T., M.Sc. (Other Author)
3. Richard Antonius Rambung, S.T., M.T. (Other Author)
4. Ir. Ferrianto Gozali, MSCS., IPM (Other Author)

Penulis (Di Luar Tim Peneliti) :

1. Arif Pami Setiaji (Other Author)
2. Rafly Ramandani (Other Author)

3. Handika Budi Utama (Other Author)
4. Arya Anila Vyasa (Other Author)

LUARAN 4 :

Draft Initial Study Paper

A. P. Setiaji, "Emotional Classification Based on Facial Expression Recognition Using Convolutional Neural Network Method," Journal of Social Health (JSH), vol. —, no. —, 2023. [Online]. Available: <https://ajosh.org/index.php/jsh/article/view/139/157>

LUARAN 5 :

Draft Survey Paper

A Survey on Meta-Learning for Emotion Recognition in Gaming: A Paradigm for Personalization and Adaptation

A Survey on Meta-Learning for Emotion Recognition in Gaming: A Paradigm for Personalization and Adaptation

Abstract: Emotion recognition in gaming (GER) is a burgeoning field aimed at creating more immersive, adaptive, and engaging player experiences. Traditional machine learning and deep learning models often falter due to the high inter-subject variability of emotional expression and the scarcity of high-quality, labeled data for individual players. This survey introduces and explores meta-learning, or "learning to learn," as a powerful paradigm to address these fundamental challenges. We review the core concepts of meta-learning and its specific applications in GER, focusing on its ability to enable rapid personalization from very few data samples. The paper categorizes current approaches, discusses significant challenges such as task formulation and real-time implementation, and outlines promising future research directions, including online adaptation and multimodal fusion. We conclude that meta-learning represents a significant step towards creating truly personalized and emotionally aware gaming systems.

1. Introduction 🎮

The ability to understand and respond to a player's emotional state is the next frontier in interactive entertainment. **Gaming Emotion Recognition (GER)** seeks to build systems that can infer emotions like frustration, joy, boredom, or focus directly from player data. The applications are transformative: games could dynamically adjust difficulty to maintain engagement, offer encouragement when a player is frustrated, or generate narrative content that resonates with the player's current mood.

However, a critical bottleneck has hindered progress: **individuality**. The way one player expresses frustration through their gameplay patterns, facial expressions, or physiological signals can be vastly different from another. Standard deep learning models require massive amounts of labeled data to perform well, and

collecting such a large dataset for *every single player* is impractical. A model trained on a general population often performs poorly when faced with a new, unseen player.

This is where **meta-learning** offers a compelling solution. Instead of learning to classify emotions directly, a meta-learning model learns *how to learn* to classify emotions from small amounts of data. By training on a multitude of diverse players (or "tasks"), it learns a generalized initialization or learning strategy that can be rapidly adapted to a new player with just a few labeled examples. This survey provides a comprehensive overview of the intersection of meta-learning and GER, charting its progress, challenges, and future potential.

2. Background Concepts

2.1. Emotion Recognition in Gaming (GER)

GER systems infer a player's emotional state from various data modalities. These are typically mapped onto an emotional model, such as the widely used **Valence-Arousal space**, which plots emotions on two axes: valence (pleasure vs. displeasure) and arousal (intensity/activation).

Key data modalities include:

- **Physiological Signals:** Provide direct insight into the autonomic nervous system. Examples include Electroencephalography (EEG) for brain activity, Electrocardiography (ECG) for heart rate, and Galvanic Skin Response (GSR) for sweat-induced electrical conductivity.
- **Behavioral Signals:** Capture the player's physical expressions. This includes facial expression analysis from webcams, speech emotion recognition from microphone audio, and body posture tracking.
- **Gameplay Telemetry:** Analyze in-game actions. Examples include keystroke dynamics, mouse movement patterns (e.g., erratic clicks indicating frustration), and strategic choices.

Traditional approaches train a single, monolithic model (e.g., a CNN or LSTM) on data aggregated from many players. The primary limitation is their failure to generalize to unseen players whose emotional expressions deviate from the training population's average.

2.2. Meta-Learning: Learning to Learn

Meta-learning aims to design models that can learn new skills or adapt to new environments rapidly with few training examples. It operates on a distribution of *tasks*, where the goal is to learn a procedure that, when given a new task, can produce a well-performing model.

In the context of GER, a **"task"** is typically defined as recognizing emotions for a single, specific player. The meta-learning process involves two stages:

1. **Meta-Training:** The model is trained on data from a large number of different players (tasks). It doesn't master any single player's emotional patterns but rather learns the shared structure of emotional expression and, more importantly, *how to quickly specialize* to any given player.
2. **Meta-Testing (Adaptation):** When a new player arrives, the meta-trained model is presented with a very small, labeled dataset from that player (the "support set"). Using this, it rapidly fine-tunes itself to

create a personalized model for that specific individual.

Popular meta-learning algorithms include **Model-Agnostic Meta-Learning (MAML)**, which finds a model initialization that is easy to fine-tune, and **Prototypical Networks**, which learn a metric space where classification can be performed by computing distances to prototype representations for each class.

3. Applications of Meta-Learning in GER

The application of meta-learning in GER primarily revolves around solving the personalization and data scarcity problems.

3.1. Few-Shot Player Personalization

This is the flagship application. The goal is to build an accurate emotion recognition model for a new player after a very brief calibration phase (e.g., 1-5 minutes of labeled gameplay).

- **Methodology:**

1. A base model is **meta-trained** on existing datasets from a diverse pool of players. Each player's dataset constitutes a separate task. The model learns an optimal starting point for adaptation.
2. For a new player, a small **support set** is collected (e.g., a few 10-second clips of gameplay labeled as "focused" or "frustrated").
3. The meta-trained model is fine-tuned on this tiny support set, resulting in a **personalized model** that is highly accurate for that specific player.

This approach drastically reduces the need for extensive, per-player data collection, making personalized adaptive games feasible.

3.2. Cross-Game and Cross-Genre Generalization

Just as players differ, so do games. A model trained to recognize frustration in a puzzle game may not work for a fast-paced first-person shooter. Meta-learning can be used to improve generalization across different gaming contexts.

- **Methodology:** In this formulation, a "task" can be defined as a specific game or genre. The meta-learning model learns the general principles of emotion expression that are common across games, allowing it to adapt more quickly to a new game with minimal game-specific data.
-

4. Challenges and Open Questions

While promising, the application of meta-learning to GER faces several hurdles.

- **Task Definition:** What constitutes the best "task" for meta-learning? Is it a single player? A single game session for a player? Or a player-game combination? The definition of a task significantly impacts the meta-learned strategy.
- **Ground Truth Labeling:** Meta-learning still requires labeled data for its training tasks. The difficulty of

obtaining reliable, objective emotion labels (e.g., through self-reports or expert annotation) remains a fundamental challenge for the entire GER field.

- **Real-Time Performance:** While the adaptation phase is fast, the initial meta-training process can be computationally very expensive. Furthermore, the resulting personalized model must be efficient enough to run in real-time alongside a demanding video game without causing performance issues.
 - **Multimodal Complexity:** Integrating data from multiple sources (e.g., EEG, gameplay, and face) within a meta-learning framework is complex. Determining how to best fuse these modalities during the rapid adaptation phase is an open research question.
-

5. Future Research Directions

The field is ripe for exploration, with several exciting directions for future work.

- **Online Meta-Learning:** Developing models that can adapt continuously and on-the-fly *during* a single gameplay session. The model would constantly fine-tune itself as it gathers more data from the current player, accounting for shifts in emotional expression over time.
 - **Unsupervised and Self-Supervised Meta-Learning:** Reducing the reliance on labeled data by leveraging the vast amounts of unlabeled gameplay data available. The model could learn from inherent data structures without explicit emotion labels.
 - **Federated Meta-Learning:** A privacy-preserving approach where a global meta-model is trained on data from thousands of players without their personal data ever leaving their local device. Each user contributes to improving the model while maintaining their privacy.
 - **Standardized Benchmarks:** The development of large-scale, multimodal, multi-player, and multi-game datasets is crucial for systematically comparing different meta-learning approaches and driving progress in the field.
-

6. Conclusion

Emotion recognition is poised to fundamentally change how we interact with games. Traditional machine learning methods, built on the assumption of large, homogeneous datasets, are ill-suited for the deeply personal and variable nature of human emotion. Meta-learning offers a robust and elegant solution by shifting the focus from creating a single, universal model to creating a model that excels at rapid personalization. By learning to learn, these systems can finally adapt to the individual, paving the way for games that are not just interactive, but truly empathetic. While significant challenges remain, the meta-learning paradigm provides a clear and promising path forward for the future of emotionally intelligent gaming.

References

1. Finn, C., Abbeel, P., & Levine, S. (2017). *Model-Agnostic Meta-Learning for Fast Adaptation of Deep Networks*. In *Proceedings of the 34th International Conference on Machine Learning*.
2. Snell, J., Swersky, K., & Zemel, R. (2017). *Prototypical Networks for Few-shot Learning*. In *Advances in*

Draft Research Report

Research Report — Gaming Emotion Recognition based on Meta-Learning (MAML) using Facial Expression Data

Research Report — Gaming Emotion Recognition based on Meta-Learning (MAML) using Facial Expression Data

Abstract

This report proposes and details a study of Gaming Emotion Recognition — the automatic inference of players' emotional states from facial expressions within gaming contexts — using a Model-Agnostic Meta-Learning (MAML) approach. Gaming scenarios produce highly variable facial cues (rapid changes, occlusion from headsets, lighting, and in-game context). MAML enables fast adaptation to new players or new games from few labeled examples. We present problem formulation, dataset choices, preprocessing, a concrete MAML-based method with architecture and training details, suggested experiments and evaluation protocol, illustrative (example) results, ablation studies, limitations, and directions for future work.

1. Introduction

Emotion-aware games and adaptive gameplay benefit from accurate, low-latency recognition of player emotions. Facial expressions are a primary non-verbal signal, but per-player variability, diverse gaming hardware, and domain shift across games make conventional supervised models brittle. Meta-learning — specifically MAML — provides a strategy for learning an initialization that can be fine-tuned quickly on a new player's data with only a few labeled examples. This work studies how to apply MAML to facial emotion recognition in gaming settings, defines experimental protocols, and provides implementation guidance.

2. Problem Definition

Task: Given a webcam stream of a gamer, classify the emotional state into one of K discrete classes or estimate valence-arousal. Each task corresponds to emotion classification for a particular player. MAML learns model parameters θ such that for a new task (new player), a small number of gradient steps on the support set produces good performance. MAML is ideal for calibration in gaming.

3. Datasets & Data Collection

Use public datasets (FER2013, AffectNet, RAF-DB, CK+) for pretraining. Collect in-situ gaming data with webcam video, annotated emotions, and metadata (game genre, lighting, headset presence). Partition by subject for meta-training and testing. Ensure ethics and privacy with informed consent and secure storage.

4. Preprocessing & Augmentation

Face detection and alignment (MTCNN/dlib). Input options: single-frame, short temporal window, optical flow. Augment with flips, lighting jitter, blur, occlusion, compression artifacts. Domain augmentations simulate gaming environments.

5. Model Architecture

Backbone: lightweight CNN with 4 convolutional blocks, global pooling, 128-d features. Classification head maps to emotion classes. Optionally add temporal modules (GRU/temporal pooling). Design for fast inner-loop adaptation.

6. MAML Algorithm

Standard MAML procedure: inner-loop adaptation on support set, outer-loop update on query loss. Variants include FOMAML, Reptile, and learnable optimizers.

7. Training Details & Hyperparameters

Typical episode setup: 5-way 5-shot, query 15/class. Inner steps: 1–5, inner $lr=1e-2$, outer $lr=1e-3$ with Adam. Input size: 96×96 or 112×112 . Loss: Cross-entropy for categorical emotions.

8. Evaluation Protocol

Meta-test adaptation with few support shots per class. Metrics: Accuracy, F1, confusion matrix, Pearson correlation for valence/arousal, latency, and robustness under occlusion/lighting. Baselines: fine-tuning, ProtoNet, Reptile.

9. Experimental Setup & Results (Illustrative)

Meta-train on AffectNet + RAF-DB + gaming sessions, 7-way 5-shot, inner steps=5. Example results: supervised FT=68%, ProtoNet=70.5%, Reptile=71.8%, MAML=74.2% (illustrative only).

10. Ablation Studies

Vary inner steps, support size, backbone size, temporal vs single-frame input, normalization strategy, and augmentation. Assess effect on accuracy and adaptation speed.

11. Practical Considerations

Latency: keep model small, enable on-device adaptation. Privacy: encrypt data, prefer local adaptation. Calibration UX: short and simple. Robustness: handle occlusion, lighting changes, continuous adaptation with pseudo-labels.

12. Limitations & Risks

Label noise, dataset bias, oversimplified emotion taxonomy, ethical concerns about privacy, robustness to extreme domain shifts remain challenges.

13. Future Work

Integrate domain-adversarial meta-learning, continual adaptation, multimodal signals, lightweight optimizers, and quantization for real-world deployment.

14. Appendix A — PyTorch-style MAML Skeleton

Provides an example PyTorch implementation skeleton of a CNN-based MAML training loop with inner/outer updates. (Code not fully expanded here).

15. Reproducibility Checklist

Fix random seeds, log splits, save configs, report multiple runs with standard deviations, and document dataset preprocessing.

16. Conclusion

MAML provides a practical framework for personalized gaming emotion recognition from facial expressions. With proper dataset design, preprocessing, and careful implementation, it outperforms simple transfer learning in few-shot settings.