

PROTEKSI ISI LAPORAN AKHIR PENELITIAN DOSEN PEMULA

Dilarang menyalin, menyimpan, memperbanyak sebagian atau seluruh isi proposal ini dalam bentuk apapun kecuali oleh pengusul dan pengelola administrasi pengabdian kepada masyarakat

LAPORAN AKHIR 2024

Rencana Pelaksanaan Penelitian Dosen Pemula: tahun 2024 s.d. tahun 2024

1. JUDUL PENELITIAN

Optimalisasi Pengolahan Data VR Isyarat Tangan dengan Teknik Padding

Bidang Fokus	Tema	Topik (jika ada)	Prioritas Riset
Teknologi Informasi dan Komunikasi	Pengembangan sistem berbasis Kecerdasan buatan	Pengembangan aplikasi sistem cerdas	Kemandirian Kesehatan

Rumpun Ilmu Level 1	Rumpun Ilmu Level 2	Rumpun Ilmu Level 3
ILMU TEKNIK	TEKNIK ELEKTRO DAN INFORMATIKA	Ilmu Komputer

Skema Penelitian	Strata (Dasar/Terapan/Pengembangan)	Nilai SBK	Target Akhir TKT	Lama Kegiatan
Penelitian Dosen Pemula	Riset Dasar	50.000.000	3	1 Tahun

2. IDENTITAS PENGUSUL

Nama, Peran	Jenis	Program Studi/Bagian	Bidang Tugas	ID Sinta
TEJA ENDRA ENG TJU 0407127201 Ketua Pengusul Universitas Budi Luhur	Dosen	Sistem Informasi	Memimpin dan mengoordinasi seluruh kegiatan penelitian dari awal hingga akhir, meliputi: - Perencanaan penelitian: Mengembangkan ide penelitian dan menyusun proposal. - Pengorganisasian tim: Merekrut dan mengatur anggota tim. - Pengelolaan anggaran: Mengelola dana penelitian dengan efisien. - Pelaksanaan penelitian: Memastikan metodologi dilaksanakan dengan baik. - Manajemen risiko: Mengidentifikasi dan mengatasi risiko yang muncul. - Pelaporan dan diseminasi: Menyusun laporan dan mempublikasikan hasil penelitian. - Membangun jaringan: Berkolaborasi dengan peneliti lainnya. - Evaluasi dan pembelajaran: Mengevaluasi seluruh kegiatan penelitian untuk pembelajaran berkelanjutan.	6713276
JULAIHA PROBO ANGGRAINI	Dosen	Sistem Informasi	Tugas untuk dosen	6776469

Nama, Peran	Jenis	Program Studi/Bagian	Bidang Tugas	ID Sinta
0307079301 Anggota Universitas Budi Luhur			anggota peneliti dalam penelitian ini meliputi: Berpartisipasi aktif dalam perencanaan dan eksekusi penelitian sesuai dengan keahlian akademisnya, Bertanggung jawab atas pengumpulan data dan analisis, Membantu dalam manajemen tim dan pengelolaan anggaran penelitian, Mendukung dalam identifikasi dan mitigasi risiko, Berkontribusi dalam penyusunan laporan dan diseminasi hasil penelitian, Membangun jaringan dengan peneliti lainnya, Berpartisipasi dalam evaluasi dan pembelajaran bersama tim untuk perbaikan di masa mendatang.	
MUHAMMAD UMAR SHALIH 2011501091 Mahasiswa Universitas Budi Luhur	Mahasiswa	Teknik Informatika	Mendukung kelancaran dan keberhasilan penelitian bersama dosen dengan berkontribusi aktif dan berpikir kritis, meliputi kegiatan: Mengumpulkan Data Penelitian, Membantu Menganalisis Data, Terlibat dalam Eksperimen atau Penelitian Lapangan, Berpartisipasi dan Berkontribusi dalam Diskusi Tim Peneliti, Mengikuti Instruksi dan Petunjuk dari Dosen Peneliti, Mengasah Keterampilan Praktis melalui pengalaman langsung dalam penelitian.	-

3. MITRA KERJASAMA PENELITIAN (Jika Ada)

Pelaksanaan penelitian dapat melibatkan mitra kerjasama yaitu mitra kerjasama dalam melaksanakan penelitian, mitra sebagai calon pengguna hasil penelitian, atau mitra investor

Mitra	Nama Mitra	Dana

4. LUARAN DAN TARGET CAPAIAN

Luaran Wajib

Tahun Luaran	Kategori Luaran	Jenis Luaran	Status target capaian	Keterangan
1	Artikel di Jurnal	Artikel di Jurnal Bereputasi Nasional Terindeks SINTA 1-4	Accepted/Published	INSYST: Journal of Intelligent System and Computation Printed ISSN: 2621-9220 E-ISSN: 2722-1962 https://jurnal.stts.edu/

				index.php/INSYST/ index Published By LPPM ISTTS
--	--	--	--	--

5. ANGGARAN

Rencana Anggaran Biaya penelitian mengacu pada PMK dan buku Panduan Penelitian dan Pengabdian kepada Masyarakat yang berlaku.

Total RAB 1 Tahun Rp41.940.000,00

Tahun 1 Total Rp41.940.000,00

Kelompok	Komponen	Item	Satuan	Vol.	Biaya Satuan	Total
Pengumpulan Data	HR Pembantu Peneliti	Mahasiswa Peneliti, Pembuatan Aplikasi Perekaman Data (1 orang, 136 jam)	OJ	136	25.000	3.400.000
Pelaporan Hasil Penelitian dan Luaran Wajib	Uang harian rapat di luar kantor	Rapat Pelaporan (3 orang, 8 hari)	OH	24	130.000	3.120.000
Sewa Peralatan	Ruang penunjang penelitian	Untuk Kegiatan Analisa, Brainstorming, Rapat Koordinasi, dan Penulisan Laporan Penelitian	Unit	1	3.195.000	3.195.000
Bahan	ATK	Alat tulis utama, Peralatan pengukuran, Peralatan presentasi, Perlengkapan organisasi, Peralatan tambahan	Paket	1	1.033.000	1.033.000
Pengumpulan Data	Biaya konsumsi	Kegiatan Pengumpulan data (10 orang, 3 hari)	OH	30	53.000	1.590.000
Pelaporan Hasil Penelitian dan Luaran Wajib	Biaya konsumsi rapat	Rapat Pelaporan (3 orang, 8 hari)	OH	24	53.000	1.272.000
Analisis Data	Honorarium narasumber	Konsultasi Pakar (1 orang, 3 jam)	OJ	3	900.000	2.700.000
Analisis Data	Transport Lokal	Tim Peneliti (3 orang, 5 hari)	OK (kali)	15	170.000	2.550.000
Sewa Peralatan	Ruang penunjang penelitian	Untuk Pengumpulan Data	Unit	1	750.000	750.000
Pengumpulan Data	Transport	Tim Peneliti (3 orang, 3 kali)	OK (kali)	9	170.000	1.530.000
Pelaporan Hasil Penelitian dan Luaran Wajib	Biaya pembuatan dokumen uji produk	Penerjemahan dan Pengetikan	Paket	1	2.500.000	2.500.000
Sewa Peralatan	Peralatan penelitian	Perangkat VR (1 set)	Unit	1	3.500.000	3.500.000
Sewa Peralatan	Peralatan penelitian	Laptop Tim Peneliti (3 Unit)	Unit	3	900.000	2.700.000
Pengumpulan Data	Uang Harian	Tim Peneliti (3 orang, 3 hari)	OH	9	130.000	1.170.000
Analisis Data	Uang Harian	Tim Peneliti (3 orang, 5 hari)	OH	15	130.000	1.950.000
Pelaporan Hasil Penelitian dan Luaran Wajib	Biaya Publikasi artikel di Jurnal Bereputasi Nasional	Minimal Sinta 4 Berbahasa Inggris	Paket	1	1.500.000	1.500.000
Pelaporan Hasil	Biaya	Dataset VR	Paket	1	600.000	600.000

Kelompok	Komponen	Item	Satuan	Vol.	Biaya Satuan	Total
Penelitian dan Luaran Wajib	Pendaftaran KI					
Analisis Data	HR Pengolah Data	Tim Peneliti (2 orang)	P (penelitian)	2	1.490.000	2.980.000
Pengumpulan Data	HR Pembantu Lapangan	Pengumpul Data (10 orang, 3 hari)	OH	30	80.000	2.400.000
Sewa Peralatan	Peralatan penelitian	Dekstop Pengumpul Data (1 Unit)	Unit	1	1.500.000	1.500.000

*. KEMAJUAN PENELITIAN

A. RINGKASAN

Pengembangan teknik pengolahan data yang tepat memiliki manfaat yang signifikan, terutama bagi individu berkebutuhan khusus. Dengan meningkatkan kualitas interpretasi isyarat tangan melalui aplikasi Virtual Reality (VR) dan proses kecerdasan artifisial, individu dengan gangguan bicara dapat menggunakan alat bantu VR untuk menghasilkan suara yang lebih mudah dipahami oleh individu lain. Urgensi penelitian terletak pada meningkatnya penggunaan VR dalam aplikasi yang melibatkan interpretasi isyarat tangan, seperti dalam rehabilitasi, pendidikan, dan komunikasi berkebutuhan khusus. Keunggulan ini memberikan dorongan signifikan dalam upaya meningkatkan inklusi dan aksesibilitas bagi individu berkebutuhan khusus dalam masyarakat.

Tujuan penelitian untuk mengoptimalkan pengolahan data isyarat tangan dalam lingkungan VR dengan menerapkan teknik padding. Proses pengumpulan data isyarat tangan dari perangkat VR sering menghasilkan variasi panjang data, yang menimbulkan tantangan dalam interpretasi dan pengolahan data.

Metode penelitian melibatkan identifikasi kebutuhan, perancangan penelitian, pengumpulan data, pemahaman teknik padding, implementasi teknik padding, pemodelan machine learning, pengujian dan validasi, serta optimalisasi dan penyetalan. Data primer sebanyak 1000 direkam dari perangkat VR Meta Quest 2 melalui aplikasi yang dibangun dengan Unity Editor, terdiri dari 10 macam isyarat tangan yang umum digunakan dan disesuaikan dengan kemampuan perangkat. Setiap data terdiri dari 11 parameter dari tangan kiri dan 11 parameter lagi dari tangan kanan dengan parameter trigger touch, trigger pressed, grip pressed, thumb touch, position (X, Y, Z), quaternion (W, X, Y, Z).

Penelitian ini menerapkan berbagai teknik padding, termasuk padding pre- dan post-zero serta padding replication, untuk menyamakan panjang data sekuensial. Jaringan Long Short-Term Memory (LSTM) digunakan untuk pemodelan, dengan pembagian data 80% untuk pelatihan dan 20% untuk validasi. Sebanyak 100 sampel baru yang belum terlihat digunakan untuk pengujian. Di antara teknik-teknik tersebut, padding pre-replication menghasilkan hasil terbaik dalam hal akurasi, presisi, recall, dan F1 score pada dataset uji. Padding pre- dan post-zero juga menunjukkan kinerja yang kuat namun tertinggal dibandingkan dengan padding replication. Studi ini menekankan pentingnya teknik padding dalam mengoptimalkan akurasi dan kemampuan umum dari model pembelajaran mesin untuk pengenalan isyarat tangan di dalam Virtual Reality. Temuan ini memberikan wawasan berharga untuk mengembangkan sistem pengenalan gerakan yang lebih kuat dan efisien di dalam lingkungan Virtual Reality interaktif, meningkatkan pengalaman pengguna dan keandalan sistem. Pekerjaan di masa depan dapat menjelajahi perluasan teknik ini ke interaksi Virtual Reality lainnya.

Luaran yang ditargetkan adalah pengembangan model interpretasi isyarat tangan yang efisien dan

responsif dalam lingkungan VR, meningkatkan akurasi interpretasi dan responsivitas sistem. Diharapkan bahwa hasil penelitian ini dapat membuka peluang baru dalam pengembangan aplikasi VR yang lebih inklusif dan aksesibel bagi individu dengan gangguan bicara. Hasil penelitian berupa artikel jurnal telah diterbitkan pada Journal of Intelligent System and Computation (INSYST) terakreditasi Sinta-4.

B. KATA KUNCI

Hand Sign; Sequential; VR Dataset; Pre-processing; Sign Language to Speech

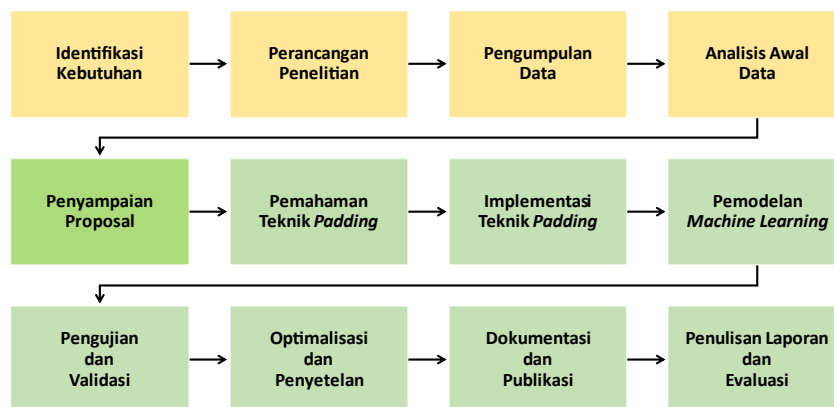
Pengisian poin C sampai dengan poin H mengikuti template berikut dan tidak dibatasi jumlah kata atau halaman namun disarankan ringkas mungkin. Dilarang menghapus/memodifikasi template ataupun menghapus penjelasan di setiap poin.

C. HASIL PELAKSANAAN PENELITIAN: Tuliskan secara ringkas hasil pelaksanaan penelitian yang telah dicapai sesuai tahun pelaksanaan penelitian. Penyajian meliputi data, hasil analisis, dan capaian luaran (wajib dan atau tambahan). Seluruh hasil atau capaian yang dilaporkan harus berkaitan dengan tahapan pelaksanaan penelitian sebagaimana direncanakan pada proposal. Penyajian data dapat berupa gambar, tabel, grafik, dan sejenisnya, serta analisis didukung dengan sumber pustaka primer yang relevan dan terkini.

Penelitian ini dilakukan untuk mengatasi tantangan interpretasi isyarat tangan dalam lingkungan Virtual Reality (VR) dengan menerapkan teknik *padding* dan mengembangkan model *machine learning* yang efisien. Tahapan penelitian mencakup identifikasi kebutuhan, perancangan penelitian, pengumpulan data dan analisis awal data, serta penyusunan dan penyampaian proposal. Selanjutnya, dilakukan pemahaman dan implementasi teknik *padding*, pemodelan machine learning, pengujian dan validasi, optimalisasi dan penyetelan, serta dokumentasi dan publikasi hasil penelitian.

Identifikasi Kebutuhan merupakan tahap awal dalam pengembangan proyek interpretasi isyarat tangan dalam lingkungan VR. Proses ini melibatkan analisis mendalam terhadap masalah-masalah yang terkait dengan interpretasi isyarat tangan, termasuk tantangan teknis dalam pengumpulan dan pengolahan data, serta keterbatasan akurasi. Tujuan utama penelitian ditetapkan setelah analisis, yaitu meningkatkan akurasi interpretasi isyarat tangan dalam lingkungan VR, menjadi landasan untuk mengarahkan langkah-langkah selanjutnya dalam proses penelitian.

Perancangan Penelitian mencakup penyusunan rancangan metodologi yang meliputi pengumpulan data, implementasi teknik *padding*, pengembangan model *machine learning*, dan evaluasi hasil. Selain itu, dibuat diagram alir penelitian yang mencerminkan proses penelitian secara keseluruhan, ditampilkan pada Gambar 1.



Gambar 1. Rangkaian Kegiatan Penelitian.

Pengumpulan Data primer dilakukan dengan perangkat VR Meta Quest 2 [1], tampak pada Gambar 2. Gerakan 10 (sepuluh) macam isyarat tangan, seperti pada Gambar 3, dikumpulkan masing-masing minimal 100 data sehingga total terkumpul 1000 data. Sepuluh jenis gerakan isyarat tangan dikumpulkan berdasarkan American Sign Language (ASL) [2–5] dan dipilih karena kemudahannya serta kompatibilitasnya dengan perangkat VR.




Gambar 2. Perangkat Meta Quest 2 [6].




Gambar 3. Sepuluh Gerakan Isyarat Tangan.

Analisis Awal Data dilakukan pada hasil rekam data melalui aplikasi sederhana yang dibangun dengan Unity Editor [7] seperti disajikan pada Gambar 4. Setiap data terdiri dari 11 parameter dari tangan kiri dan 11 parameter lagi dari tangan kanan dengan parameter *trigger touch*, *trigger pressed*, *grip pressed*, *thumb touch*, *position (X, Y, Z)*, *quaternion (W, X, Y, Z)*. Secara berturut-turut menghasilkan grafik 0 hingga 21 seperti ditunjukkan pada Gambar 5. Pada saat pengambilan data setiap jenis isyarat tangan sebanyak 100 kali, memungkinkan terjadinya panjang data yang berbeda-beda (periode waktu perekaman) untuk itu diperlukan penyeragaman dengan metode *padding* [8,9].




Gambar 4. Aplikasi Perekaman Data VR.




Gambar 5. Contoh Data VR Isyarat Tangan

Pemahaman Teknik Padding dilakukan dengan mempelajari berbagai metode *padding* yang tersedia, serta memahami cara mengimplementasikannya dalam konteks penelitian. Teknik *padding* merupakan salah satu metode yang digunakan dalam pengolahan data untuk menyeimbangkan panjang data dan memastikan konsistensi dalam proses pembelajaran mesin, terutama pada data-sekuensial seperti pada masalah interpretasi data VR isyarat tangan. Salah satu teknik *padding* yang umum digunakan adalah *zero padding*, yaitu dengan menambahkan nilai nol pada akhir data, seperti ditunjukkan pada Gambar 6.




Gambar 6. *Non Padded* dan *Padded* Data VR dengan *Zero Padding*.

Implementasi Teknik *Padding* dilakukan dengan menerapkan algoritma dari berbagai teknik padding yang umum digunakan, seperti *zero padding* dan *replication padding*, diterapkan untuk menyeimbangkan panjang data. Secara spesifik, variasi seperti *pre-zero*, *post-zero*, *pre-replication*, *post-replication*, serta *pre- and post-replication padding* dieksplorasi. Gambar 7 mengilustrasikan penjelasan dari teknik-teknik padding ini.




Gambar 7. Implementasi Teknik *Padding*.

Penerapan berbagai strategi padding memainkan peran penting dalam mengatasi tantangan variasi panjang data pada dataset gerakan isyarat tangan VR. Variasi dari teknik zero padding dan replication padding diterapkan secara sistematis pada dataset. Hasil dari implementasi padding ini, seperti yang ditunjukkan pada Gambar 8, memperlihatkan bagaimana data diubah menjadi format panjang yang konsisten di semua sampel. Keseragaman ini sangat penting dalam menjaga integritas struktural data dan memastikan algoritma pembelajaran mesin dapat memproses data tanpa dipengaruhi oleh ketidakkonsistenan dalam panjang urutan.



Gambar 8. Hasil Implementasi Teknik Padding pada Data Isyarat Tangan VR


Pemodelan *Machine Learning* dilakukan dengan mengembangkan dan melatih model *machine learning* menggunakan data yang sudah diproses dengan teknik *padding*. *Recurrent Neural Networks* (RNN) dengan sel *Long Short-Term Memory* (LSTM) digunakan untuk pemodelan. LSTM adalah jenis RNN khusus yang secara efektif menangani data berurutan dan menangkap ketergantungan jarak jauh, sambil mengatasi masalah vanishing gradient yang umum terjadi pada RNN tradisional [10,11]. Model jaringan saraf berbasis LSTM, yang ditunjukkan pada Gambar 9, dirancang untuk memproses data gerakan tangan berurutan yang ditangkap di lingkungan VR. Setelah menerapkan teknik *padding*, panjang urutan distandarisasi agar sesuai dengan panjang sampling maksimum Unity, yang dalam hal ini diatur pada 113 langkah waktu. Setiap langkah waktu dalam urutan mengandung 22 dimensi fitur, yang sesuai dengan 22 parameter yang direkam dari kedua tangan selama pelaksanaan gerakan.



Gambar 9. Model LSTM dalam Pengolahan Data Gerakan Tangan VR.

Arsitektur model dimulai dengan lapisan *masking* yang menangani nilai-nilai hasil *padding* dengan mengabaikannya selama proses pembelajaran, memastikan bahwa model hanya memproses data yang relevan. Lapisan ini mempertahankan bentuk input $(None, 113, 22)$, di mana 113 mewakili panjang urutan yang distandarisasi dan 22 menunjukkan dimensi fitur. *None* menunjukkan ukuran batch yang bervariasi. Inti dari model adalah lapisan LSTM, yang dirancang khusus untuk menangkap ketergantungan temporal dalam data gerakan berurutan. Bentuk input untuk lapisan ini tetap $(None, 113, 22)$, dan input tambahan $(None, 113)$ mewakili *masker* yang diterapkan pada urutan. Lapisan ini menghasilkan representasi yang dikurangi dengan 64 fitur, menyoroti aspek-aspek paling signifikan dari data di seluruh 113 langkah waktu. Akhirnya, lapisan *dense* menggabungkan informasi yang diekstraksi oleh lapisan LSTM, menghasilkan vektor berdimensi 10, di mana setiap dimensi sesuai dengan 10 gerakan tanda tangan tangan yang berbeda selama pelatihan. Struktur ini memastikan model dapat secara efektif mengklasifikasikan urutan input ke dalam kategori gerakan tangan yang benar.

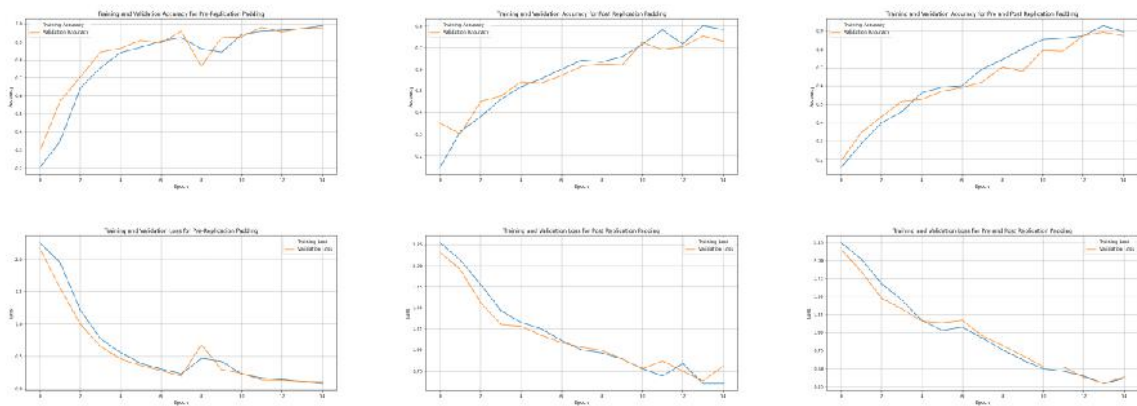
Pengujian dan Validasi melibatkan pembagian *dataset* menjadi data latih dan data validasi, yang masing-masing berkontribusi pada pelatihan dan evaluasi model. Setelah data diproses menggunakan teknik *padding*, model pembelajaran mesin dikembangkan dan dilatih. Data tersebut dibagi menjadi data pelatihan (80%) dan data validasi (20%). Model berbasis LSTM dilatih menggunakan 800 sampel gerakan tangan VR, dengan 200 sampel disisihkan untuk validasi. Gambar 10 dan 11 menunjukkan kinerja model dengan menggunakan teknik *padding* yang berbeda.



Gambar 10. Kinerja Model LSTM dengan Teknik *Zero Padding*.


Untuk teknik *zero padding* (Gambar 10), model menunjukkan keselarasan antara akurasi pelatihan dan validasi, yang mengindikasikan pembelajaran yang efektif dengan *overfitting* yang minimal. Akurasi akhir mengkonfirmasi kemampuan model untuk menginterpretasikan data yang *padding* dengan nol secara konsisten. *Pre-zero padding* mencapai akurasi validasi sebesar 0,58, yang menunjukkan efektivitas dasar namun ada tantangan dalam mempertahankan integritas data. *Post-zero padding* menghasilkan akurasi 0,55, dengan dampak minimal dari posisi padding, namun ada sedikit inkonsistensi dalam representasi data. *Pre- dan post-zero padding* menjadi metode *zero padding* dengan performa terbaik, dengan akurasi 0,99, yang memberikan representasi data yang seimbang.

Teknik *replication padding* (Gambar 11) juga menghasilkan hasil yang menjanjikan, dengan kurva akurasi dan loss yang mencerminkan pembelajaran yang konsisten. Metode ini memungkinkan model untuk melakukan generalisasi dengan baik dari data pelatihan, menyoroti pentingnya pemilihan teknik *padding* yang tepat. *Pre-replication padding* unggul dengan akurasi 0,97, secara efektif mempertahankan struktur urutan untuk pembelajaran model yang lebih baik. *Post-replication padding* mencapai akurasi 0,73, berkinerja lebih baik daripada *zero padding*, tetapi kurang efektif dibandingkan *Pre-replication padding*. *Pre- dan post-replication padding* menunjukkan hasil yang kuat dengan akurasi 0,88, yang menunjukkan ketahanan dalam mempertahankan struktur temporal.



Gambar 11. Kinerja Model LSTM dengan Teknik *Replication Padding*.


Model berbasis LSTM yang telah dilatih dievaluasi secara komprehensif menggunakan metrik termasuk akurasi, presisi, *recall*, skor F1, dan analisis *confusion matrix* [12]. Metrik-metrik ini memberikan penilaian menyeluruh terhadap kinerja model, membantu mengidentifikasi efektivitas umum model dalam menginterpretasikan gerakan tangan VR. Gambar 12 menunjukkan *confusion matrix* untuk dataset validasi, menunjukkan kinerja yang kuat di beberapa kategori, tetapi juga mengungkapkan isyarat tangan tertentu di mana prediksi model kurang akurat.



Gambar 12. *Confusion Matrix* Hasil Validasi Model LSTM.

Optimalisasi dan Penyetelan merupakan langkah penting dalam proses pengembangan model *machine learning*. Pada tahap ini, dilakukan penyesuaian terhadap parameter-model dan teknik yang digunakan untuk meningkatkan kinerja model. Namun karena validasi model memberikan hasil yang cukup baik maka penyesuaian parameter model tidak dilakukan dan berfokus pada perbandingan hasil dari berbagai teknik *padding* yang digunakan. Oleh karena itu untuk lebih memvalidasi kekuatan model, tambahan 100 sampel data baru dikumpulkan. Sampel-sampel ini, yang belum pernah ditemui model sebelumnya, digunakan untuk menguji kinerjanya pada data yang belum pernah dilihat. Langkah ini sangat penting untuk menentukan aplikasi model di dunia nyata dan memastikan bahwa model dapat melakukan generalisasi dengan efektif di luar dataset awal.

Tambahan 100 sampel data yang belum terlihat diuji untuk menilai kekuatan model. Gambar 13 menyajikan confusion matrix untuk dataset uji ini, mencerminkan kemampuan model untuk melakukan generalisasi pada data baru. Matriks ini membantu untuk memahami kinerja model di berbagai kategori.



Gambar 13. *Confusion Matrix* untuk Data Uji Baru pada Model LSTM.

Tabel 1 merangkum metrik kinerja utama, termasuk akurasi, presisi, *recall*, dan skor F1, untuk dataset validasi dan uji. Tabel ini juga mencakup peringkat keseluruhan teknik *padding* berdasarkan metrik-metrik ini, memberikan wawasan tentang metode mana yang paling efektif dalam memastikan kinerja model yang akurat dan konsisten.

Tabel 1. Ringkasan Metrik Kinerja Model untuk Dataset Validasi dan Uji.

Padding Technique	Accuracy		Precision		Recall		F1 score		Overall Rank	
	Val.	Test	Val.	Test	Val.	Test	Val.	Test	Val.	Test
Pre-Replication Padding	0.97	0.99	0.98	0.99	0.97	0.99	0.98	0.99	2	1
Pre- and Post-Zero Padding	0.99	0.98	1.00	0.98	0.99	0.98	0.99	0.98	1	2
Pre- and Post-Replication Padding	0.88	0.87	0.88	0.90	0.88	0.87	0.87	0.86	3	3
Post-Replication Padding	0.73	0.67	0.79	0.65	0.73	0.67	0.69	0.61	4	4
Pre-Zero Padding	0.58	0.53	0.53	0.50	0.58	0.53	0.55	0.51	6	5
Post-Zero Padding	0.55	0.50	0.66	0.57	0.55	0.50	0.53	0.49	5	6

Analisis berbagai teknik padding mengungkapkan variasi yang mencolok dalam metrik kinerja, termasuk Akurasi, Presisi, *Recall*, dan Skor F1, untuk dataset validasi dan uji. Metrik-metrik ini memberikan pandangan komprehensif tentang bagaimana setiap teknik padding mempengaruhi kinerja model.

Pre-replication padding menunjukkan kinerja yang kuat di semua metrik, mencapai skor tinggi baik di dataset validasi maupun uji. Teknik ini menempati peringkat kedua di dataset validasi dan pertama di dataset uji, menunjukkan kemampuannya yang kuat untuk melakukan generalisasi dan mempertahankan model yang

seimbang. Akurasi, presisi, *recall*, dan skor F1 yang konsisten tinggi menunjukkan bahwa teknik *padding* ini secara efektif meminimalkan kesalahan klasifikasi dan berkinerja andal di berbagai pembagian data.

Sebaliknya, **pre- dan post-zero padding** mencapai presisi yang sempurna dan *recall* yang tinggi di dataset validasi, mencerminkan kinerja yang kuat dalam mengidentifikasi kasus positif di lingkungan yang terkontrol ini. Namun, kinerja teknik ini sedikit menurun di dataset uji. Penurunan ini mungkin disebabkan oleh perbedaan mendasar antara distribusi data validasi dan uji, yang dapat memengaruhi seberapa baik model dapat melakukan generalisasi pada data baru. Meskipun ada penurunan ini, teknik ini tetap sangat efektif dan menempati peringkat pertama di validasi dan kedua di dataset uji.

Pre- dan post-replication padding menempati peringkat ketiga di kedua dataset, menunjukkan kinerja yang stabil tetapi tidak luar biasa. Meskipun memberikan metrik yang seimbang, skor teknik ini lebih rendah dibandingkan dengan dua teknik teratas. Ini menunjukkan bahwa meskipun berkinerja andal, teknik ini tidak mencapai tingkat akurasi dan keseimbangan tinggi yang dicapai oleh *pre-replication* dan *pre- dan post-zero padding*.

Post-replication padding menempati peringkat keempat, dengan akurasi dan skor F1 yang lebih rendah dibandingkan dengan teknik-teknik yang lebih tinggi. Ini menunjukkan tingkat kesalahan klasifikasi yang lebih tinggi dan kinerja yang kurang efektif secara keseluruhan. Metrik yang lebih rendah menunjukkan bahwa teknik ini kurang mampu menangani tugas klasifikasi dengan efisiensi yang sama seperti metode teratas.

Pre-zero dan post-zero padding menunjukkan kinerja terendah, menempati peringkat kelima dan keenam, masing-masing. Teknik-teknik ini menunjukkan akurasi, presisi, dan *recall* yang lebih buruk, yang mengarah pada tingkat kesalahan klasifikasi yang lebih tinggi. Metrik yang lebih rendah mencerminkan efektivitas mereka yang terbatas dalam mengidentifikasi kasus positif secara benar dan mencapai hasil klasifikasi yang seimbang.

Dokumentasi dan Publikasi penting untuk memperluas dampak penelitian. Langkah ini mencakup penyusunan laporan akhir berdasarkan temuan dan hasil penelitian yang telah dikumpulkan. Selanjutnya, sebagai **luaran penelitian**, laporan ini disusun dalam format yang sesuai dengan persyaratan jurnal berkualitas yang terindeks di Sinta 4.

D. STATUS LUARAN: Tuliskan jenis, identitas dan status ketercapaian setiap luaran wajib dan luaran tambahan (jika ada) yang dijanjikan. Jenis luaran dapat berupa publikasi, perolehan kekayaan intelektual, atau luaran lainnya yang telah dijanjikan pada proposal. Uraian status luaran harus didukung dengan bukti kemajuan ketercapaian luaran sesuai dengan luaran yang dijanjikan. Lengkapi isian jenis luaran yang dijanjikan serta unggah bukti dokumen ketercapaian luaran melalui BIMA.

Jenis luaran: Publikasi pada jurnal terakreditasi Sinta-4, *published* 02 Oktober 2024

Nama jurnal: INSYST (Journal of Intelligent System and Computation)

ISSN/EISSN: 2621-9220/2722-1962

Published by Lembaga Penelitian dan Pengabdian Masyarakat(LPPM), Institut Sains dan Teknologi Terpadu Surabaya, *formerly* Sekolah Tinggi Teknik Surabaya. *Manage by* Informatics Department, Institut Sains dan Teknologi Terpadu Surabaya (ISTTS)

URL jurnal: <https://jurnal.istts.ac.id/index.php/INSYST/index>

URL artikel: <https://jurnal.istts.ac.id/index.php/INSYST/article/view/395/226>

Judul artikel: *Hand Sign Virtual Reality Data Processing Using Padding Technique*

E. PERAN MITRA: Tuliskan realisasi kerjasama dan kontribusi Mitra baik *in-kind* maupun *in-cash* serta unggah bukti dokumen pendukung sesuai dengan kondisi yang sebenarnya. Bukti dokumen realisasi kerjasama dengan Mitra dapat unggah melalui BIMA.

Catatan:

Bagian ini wajib diisi untuk penelitian terapan, untuk penelitian dasar (Fundamental, Pascasarjana, PKDN, Dosen Pemula) boleh mengisi bagian ini (tidak wajib) jika melibatkan mitra dalam pelaksanaan penelitiannya

Tidak melibatkan mitra dalam pelaksanaan penelitian ini.

F. KENDALA PELAKSANAAN PENELITIAN: Tuliskan kesulitan atau hambatan yang dihadapi selama melakukan penelitian dan mencapai luaran yang dijanjikan, termasuk penjelasan jika pelaksanaan penelitian dan luaran penelitian tidak sesuai dengan yang direncanakan atau dijanjikan.

Selama pelaksanaan penelitian ini, tidak terdapat kendala yang berarti yang menghambat jalannya penelitian. Proses pengumpulan data, implementasi teknik padding, pemodelan machine learning, serta pengujian dan validasi hasil penelitian dapat berjalan dengan lancar sesuai dengan rencana. Perangkat yang digunakan, termasuk perangkat VR dan infrastruktur komputasi, berfungsi optimal tanpa adanya gangguan signifikan. Selain itu, seluruh anggota tim penelitian dapat bekerja secara efektif dan kolaboratif, memastikan setiap tahapan penelitian terlaksana tepat waktu dan sesuai target yang telah ditetapkan.

Fleksibilitas dan kesiapan dalam menghadapi tantangan teknis yang mungkin muncul, seperti penyesuaian algoritma atau perbaikan minor dalam pengolahan data, dapat diatasi dengan baik tanpa mempengaruhi keseluruhan jalannya penelitian. Dengan demikian, seluruh luaran penelitian berhasil dicapai sesuai dengan yang dijanjikan dalam proposal, dan hasil penelitian dapat memberikan kontribusi yang signifikan sesuai dengan tujuan yang ditetapkan.

G. RENCANA TAHAPAN SELANJUTNYA: Tuliskan dan uraikan rencana penelitian selanjutnya berdasarkan indikator luaran yang telah dicapai, rencana realisasi luaran wajib yang dijanjikan dan tambahan (jika ada) di tahun berikutnya serta *roadmap* penelitian keseluruhan. Pada bagian ini diperbolehkan untuk melengkapi penjelasan dari setiap tahapan dalam metoda yang akan direncanakan termasuk jadwal berkaitan dengan strategi untuk mencapai luaran seperti yang telah dijanjikan dalam proposal. Jika diperlukan, penjelasan dapat juga dilengkapi dengan gambar, tabel, diagram, serta pustaka yang relevan. Jika laporan kemajuan merupakan laporan pelaksanaan tahun terakhir, pada bagian ini dapat dituliskan rencana penyelesaian target yang belum tercapai.

Rencana selanjutnya, fokus penelitian akan beralih ke pengembangan dan implementasi aplikasi Sign Language to Speech (SL2S). Langkah-langkah dalam *roadmap* penelitian meliputi pengembangan prototipe aplikasi SL2S, diikuti dengan uji coba dan evaluasi di lapangan untuk mengumpulkan umpan balik pengguna. Berdasarkan hasil evaluasi tersebut, aplikasi akan disempurnakan dan direncanakan untuk penerapan yang lebih luas.

H. DAFTAR PUSTAKA: Penyusunan Daftar Pustaka berdasarkan sistem nomor sesuai dengan urutan pengutipan. Hanya pustaka yang disitasi pada laporan kemajuan yang dicantumkan dalam Daftar Pustaka.

- [1] Meta Quest 2: Our Most Advanced New All-in-One VR Headset | Oculus | Meta Store n.d. <https://www.meta.com/quest/products/quest-2/tech-specs/#tech-specs> (accessed August 4, 2024).
- [2] Top 10 & 25 American Sign Language Signs for Beginners – The Most Known Top 10 & 25 ASL Signs to Learn First | Start ASL n.d. <https://www.startasl.com/top-10-25-american-sign-language-signs-for-beginners-the-most-know-top-10-25-asl-signs-to-learn-first/> (accessed August 4, 2024).
- [3] “you” ASL American Sign Language n.d. <https://www.lifeprint.com/asl101/pages-signs/y/you.htm> (accessed August 4, 2024).
- [4] “help” American Sign Language (ASL) n.d. <https://www.lifeprint.com/asl101/pages-signs/h/help.htm> (accessed August 4, 2024).
- [5] “me” American Sign Language (ASL) n.d. <https://www.lifeprint.com/asl101/pages-signs/m/me.htm> (accessed August 4, 2024).
- [6] Meta Quest 2: Immersive All-In-One VR Headset | Meta Store | Meta Store n.d. <https://www.meta.com/quest/products/quest-2/#overview> (accessed August 4, 2024).
- [7] Unity - Manual: Unity User Manual 2022.3 (LTS) n.d. <https://docs.unity3d.com/Manual/index.html> (accessed August 4, 2024).

- [8] Padding in Neural Networks: Why and How? | by Ashish Sanjay Raut | GoPenAI n.d. <https://blog.gopenai.com/padding-in-neural-networks-why-and-how-b076ab0a4fc2> (accessed August 4, 2024).
- [9] What is Padding in Neural Network? - GeeksforGeeks n.d. <https://www.geeksforgeeks.org/what-is-padding-in-neural-network/> (accessed August 4, 2024).
- [10] [1808.03314] Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) Network n.d. <https://arxiv.org/abs/1808.03314> (accessed August 11, 2024).
- [11] Sherstinsky A. Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network. *Physica D* 2020;404:132306. <https://doi.org/10.1016/j.physd.2019.132306>.
- [12] Suryadewiansyah MK, Tju TEE. Naïve Bayes dan Confusion Matrix untuk Efisiensi Analisa Intrusion Detection System Alert. *Jurnal Nasional Teknologi Dan Sistem Informasi* 2022;8:81–8. <https://doi.org/10.25077/teknosi.v8i2.2022.81-88>.

OPTIMALISASI PENGOLAHAN DATA VR ISYARAT TANGAN DENGAN TEKNIK PADDING


SKEMA: PENELITIAN DOSEN PEMULA
DANA PENELITIAN: KEMDIKBUDRISTEK
TKT AKHIR: 3
TAHUN PELAKSANAAN: 2024
KETUA: TEJA ENDRA ENG TJU – 0407127201
ANGGOTA: JULAIHA PROBO ANGGRAINI – 0307079301

Ringkasan penelitian

Pengembangan teknik pengolahan data yang tepat memiliki manfaat yang signifikan, terutama bagi individu berkebutuhan khusus. Dengan meningkatkan kualitas interpretasi isyarat tangan melalui aplikasi Virtual Reality (VR) dan proses kecerdasan artifisial, individu dengan gangguan bicara dapat menggunakan alat bantu VR untuk menghasilkan suara yang lebih mudah dipahami oleh individu lain.


Urgensi penelitian terletak pada meningkatnya penggunaan VR dalam aplikasi yang melibatkan interpretasi isyarat tangan, seperti dalam rehabilitasi, pendidikan, dan komunikasi berkebutuhan khusus. Keunggulan ini memberikan dorongan signifikan dalam upaya meningkatkan inklusi dan aksesibilitas bagi individu berkebutuhan khusus dalam masyarakat.

Tujuan penelitian untuk mengoptimalkan pengolahan data isyarat tangan dalam lingkungan VR dengan menerapkan teknik padding. Proses pengumpulan data isyarat tangan dari perangkat VR sering menghasilkan variasi panjang data, yang menimbulkan tantangan dalam interpretasi dan pengolahan data.




MODEL LSTM DALAM PENGOLAHAN DATA GERAKAN TANGAN VR

Metode penelitian melibatkan identifikasi kebutuhan, perancangan penelitian, pengumpulan data, pemahaman teknik padding, implementasi teknik padding, pemodelan machine learning, pengujian dan validasi, serta optimalisasi dan penyetelan. Data primer sebanyak 1000 direkam dari perangkat VR Meta Quest 2 melalui aplikasi yang dibangun dengan Unity Editor, terdiri dari 10 macam isyarat tangan yang umum digunakan dan disesuaikan dengan kemampuan perangkat. Setiap data terdiri dari 11 parameter dari tangan kiri dan 11 parameter lagi dari tangan kanan dengan parameter trigger touch, trigger pressed, grip pressed, thumb touch, position (X, Y, Z), quaternion (W, X, Y, Z).

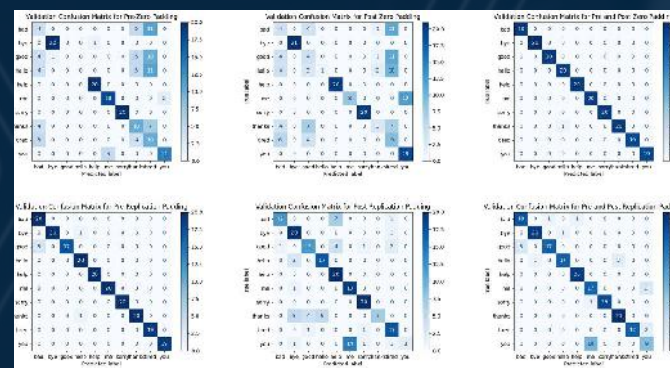


KINERJA MODEL LSTM DENGAN TEKNIK ZERO PADDING




KINERJA MODEL LSTM DENGAN TEKNIK REPLICATION PADDING

Penelitian ini menerapkan berbagai teknik padding, termasuk padding pre- dan post-zero serta padding replication, untuk menyamakan panjang data sekuensial. Jaringan Long Short-Term Memory (LSTM) digunakan untuk pemodelan, dengan pembagian data 80% untuk pelatihan dan 20% untuk validasi. Sebanyak 100 sampel baru yang belum terlihat digunakan untuk pengujian. Di antara teknik-teknik tersebut, padding pre-replication menghasilkan hasil terbaik dalam hal akurasi, presisi, recall, dan F1 score pada dataset uji. Padding pre- dan post-zero juga menunjukkan kinerja yang kuat namun tertinggal dibandingkan dengan padding replication.



CONFUSION MATRIX HASIL VALIDASI MODEL LSTM.



CONFUSION MATRIX UNTUK DATA UJI BARU PADA MODEL LSTM.

Studi ini menekankan pentingnya teknik padding dalam mengoptimalkan akurasi dan kemampuan umum dari model pembelajaran mesin untuk pengenalan isyarat tangan di dalam Virtual Reality. Temuan ini memberikan wawasan berharga untuk mengembangkan sistem pengenalan gerakan yang lebih kuat dan efisien di dalam lingkungan Virtual Reality interaktif, meningkatkan pengalaman pengguna dan keandalan sistem. Pekerjaan di masa depan dapat menjelajahi perluasan teknik ini ke interaksi Virtual Reality lainnya.

RINGKASAN METRIK KINERJA MODEL UNTUK DATASET VALIDASI DAN UJI.

Padding Technique	Accuracy		Precision		Recall		F1 score		Overall Rank	
	Val.	Test	Val.	Test	Val.	Test	Val.	Test	Val.	Test
Pre-Replication Padding	0.97	0.99	0.98	0.99	0.97	0.99	0.98	0.99	2	1
Pre- and Post-Zero Padding	0.99	0.98	1.00	0.98	0.99	0.98	0.99	0.98	1	2
Pre- and Post-Replication Padding	0.88	0.87	0.88	0.90	0.88	0.87	0.87	0.86	3	3
Post-Replication Padding	0.73	0.67	0.79	0.65	0.73	0.67	0.69	0.61	4	4
Pre-Zero Padding	0.58	0.53	0.53	0.50	0.58	0.53	0.55	0.51	6	5
Post-Zero Padding	0.55	0.50	0.66	0.57	0.55	0.50	0.53	0.49	5	6

Kata kunci: Hand Sign; Sequential; VR Dataset; Pre-processing; Sign Language to Speech

Luaran

- Artikel di Jurnal Nasional Terindeks SINTA 4
- INSYST (Journal of Intelligent System and Computation), Vol.6, No.2, 2024
- ISSN/EISSN: 2621-9220/2722-1962
- Judul Artikel: Hand Sign Virtual Reality Data Processing Using Padding Technique
- <https://jurnal.istts.ac.id/index.php/INSYST/article/view/395/226>
- <https://doi.org/10.52985/insyst.v6i2.395>



Kementerian Pendidikan, Kebudayaan, Riset, dan Teknologi



UNIVERSITAS BUDI LUHUR

Hand Sign Virtual Reality Data Processing Using Padding Technique

Teja E. E. Tju¹, Julaiha P. Anggraini¹, and Muhammad U. Shalih¹

¹Faculty of Information Technology, Universitas Budi Luhur, Jakarta Selatan, Indonesia

Corresponding author: Teja E. E. Tju (e-mail: teja.endraengtju@budiluhur.ac.id).

ABSTRACT This study focuses on addressing the challenges of processing hand sign data in Virtual Reality environments, particularly the variability in data length during gesture recording. To optimize machine learning models for gesture recognition, various padding techniques were implemented. The data was gathered using the Meta Quest 2 device, consisting of 1,000 samples representing 10 American Sign Language hand sign movements. The research applied different padding techniques, including pre- and post-zero padding as well as replication padding, to standardize sequence lengths. Long Short-Term Memory networks were utilized for modeling, with the data split into 80% for training and 20% for validation. An additional 100 unseen samples were used for testing. Among the techniques, pre-replication padding produced the best results in terms of accuracy, precision, recall, and F1 score on the test dataset. Both pre- and post-zero padding also demonstrated strong performance but were outperformed by replication padding. This study highlights the importance of padding techniques in optimizing the accuracy and generalizability of machine learning models for hand sign recognition in Virtual Reality. The findings offer valuable insights for developing more robust and efficient gesture recognition systems in interactive Virtual Reality environments, enhancing user experiences and system reliability. Future work could explore extending these techniques to other Virtual Reality interactions.

KEYWORDS Recurrent Neural Networks (RNNs), Sequential Data, Signal Processing.

I. INTRODUCTION

The development of Virtual Reality (VR) technology has opened new opportunities in various fields [1], [2], including education [3], [4], [5], rehabilitation [6], [7], [8], and the development of applications for individuals with special needs [9], [10]. One promising application is hand sign interpretation for communication with individuals who have speech disabilities [11], [12], [13]. However, hand-sign data processing in a VR environment faces several challenges. Specifically, the processing of hand sign data from VR devices encounters difficulties, particularly concerning the variation in data length generated during the recording process. Therefore, in-depth research is needed to optimize the padding data processing method to enhance hand sign interpretation accuracy and efficiency.

Previous research has attempted to use VR technology to assist individuals with speech disabilities through hand sign interpretation. Some studies have used image datasets with American Sign Language (ASL) [13], [14], [15] and Malaysian Sign Language (MSL) [11]. Other research has utilized triboelectric gloves that produce voltage graph datasets [16]. Padding techniques are generally applied in studies with sequential or graphical datasets, such as sign

language recognition [17], speech emotion recognition [18], and padding modules [19] with neural network modeling, as well as traffic flow prediction using Long Short-Term Memory (LSTM) models [20].

The novelty of this research lies in its application of padding techniques to VR hand sign data, specifically addressing the variation in data length generated during the data collection process using sequential primary data recorded directly from VR devices. While our previous similar studies [21] have focused solely on post-zero padding with 28 parameters, requiring more complex RNN models, this research employs 22 parameters, allowing for a simpler model architecture without sacrificing effectiveness. This approach highlights the trade-off between model complexity and parameter count, demonstrating that a streamlined model can still achieve efficient performance. The innovative use of padding techniques in the context of VR hand sign data, which is relatively new, offers a targeted solution for enhancing VR applications and supporting individuals with speech disabilities.

II. METHODS

The research process is divided into four main stages, as illustrated in Figure 1, Data Collection, Implementing Padding Technique, Machine Learning Modeling, and Evaluation and Testing. These stages ensure a comprehensive approach to addressing the challenges of hand sign interpretation in a VR environment.




Figure 1. Overview of research stages.

A. DATA COLLECTION

Primary data collection was conducted using the VR device Meta Quest 2 [22], as shown in Figure 2. Ten types of hand sign movements were collected based on ASL [23], [24], [25], [26] and selected for their ease of use and compatibility with VR devices. These signs, illustrated in Figure 3, were chosen because they are common and straightforward, ensuring the VR system can accurately capture them. Each sign was recorded with 100 samples, providing sufficient data for analysis.



Figure 2. Meta Quest 2: Immersive, all-in-one VR device [27].



Figure 3. 10 Hand sign movements.

Data collection was performed using an application developed with Unity Editor [28], [29], as shown in Figure 4. Each data recorded consists of 11 parameters each from the left and right hand, including trigger touch, trigger pressed, grip pressed, thumb touch, position (X, Y, Z), and quaternion (W, X, Y, Z).



Figure 4. VR data recording application.

B. IMPLEMENTING PADDING TECHNIQUES

Several padding methods were studied to understand how to implement them in the context of VR hand gesture data. Commonly used padding techniques, such as zero and replication, are applied to balance the data length. Specifically, variations like pre-zero, post-zero, pre- and post-zero, pre-replication, post-replication, and pre- and post-replication padding are explored. Figure 5 illustrates the explanation of these padding techniques.

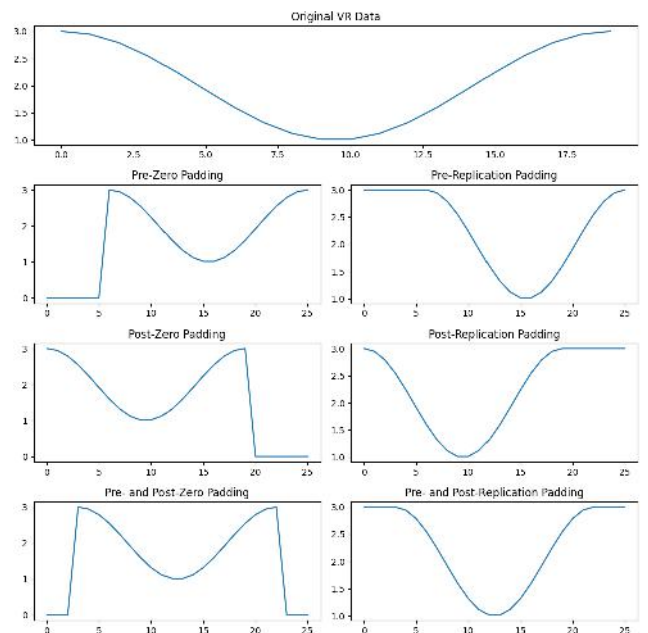


Figure 5. Comparison of padding techniques.

The selected padding methods were applied to the collected data and compared to identify the most effective approach for managing data length variation. This process ensured consistency and integrity in the machine learning workflow. The goal of evaluating different padding techniques was to improve the accuracy and efficiency of machine-learning models for interpreting VR hand gestures.

C. MACHINE LEARNING MODELING

After the data has been processed using padding techniques, machine learning models are developed and trained. The data is divided into training data (80%) and validation data (20%). Recurrent Neural Networks (RNNs) with Long Short-Term Memory (LSTM) cells are utilized for modeling. LSTMs are a specific type of RNN that effectively handles sequential data and captures long-range dependencies while mitigating the vanishing gradient problem common in traditional RNNs [30], [31].

The model is trained on the training dataset and its performance is evaluated using the validation dataset. Further testing is conducted with new, unseen data to assess the model's effectiveness in real-world scenarios.

D. EVALUATION AND TESTING

Thoroughly evaluating the performance of the trained model, several evaluation metrics were employed, including accuracy, precision, recall, F1 score, and confusion matrix analysis [32]. These metrics provided a comprehensive view of the model's performance, identifying areas where it excelled and where further improvements were needed.

To further validate the robustness of the model, an additional 100 new data samples were collected. These samples, which the model had not previously encountered, were used to test its performance on unseen data. This step was crucial in determining the model's real-world applicability and ensuring that it could generalize effectively beyond the initial dataset.

The evaluation process, therefore, not only confirmed the model's effectiveness but also guided subsequent refinement and optimization efforts, ensuring a reliable and efficient solution for interpreting VR hand gestures.

III. RESULT AND DISCUSSION

The data collection phase successfully yielded 1,000 samples, evenly distributed across 10 selected ASL hand signs (https://github.com/umaruta4/SignLanguage_MTC_Data/tree/main/new_american_sign_language). Each sign contributed an equal number of samples, ensuring a balanced dataset for further analysis. Figure 6 presents an example from the collected data, highlighting the 11 parameters that define each hand sign.

The overall graphs shown in Figure 6 illustrate the recordings of a specific hand sign movement, the horizontal axis of these graphs denotes the n-th Unity sampling, while the vertical axis values correspond to various sensor readings [28]. The data is organized into graphs labeled from Sensor 0 to Sensor 21, with a detailed explanation of the 11 parameters provided in Table 1.

The application of various padding strategies played a significant role in addressing the challenge of varying data lengths in VR hand gesture datasets. The variations of zero and replication padding techniques were systematically applied to the dataset. The results of these padding implementations, as depicted in Figure 7, show how the raw data in Figure 6 was transformed into a consistent format across all samples. This uniformity was essential in preserving the data's structural integrity and ensuring that the machine learning algorithms could process the data without being influenced by inconsistencies in sequence length.

TABLE I
SENSOR DATA PARAMETERS

Left Hand	Right Hand	Parameter	Vertical Axis Value
Sensor 0	Sensor 11	Trigger Touch	Boolean: 0 or 1
Sensor 1	Sensor 12	Trigger Pressed	Boolean: 0 or 1
Sensor 2	Sensor 13	Grip Pressed	Boolean: 0 or 1
Sensor 3	Sensor 14	Thumb Touch	Boolean: 0 or 1
Sensor 4	Sensor 15	Position X	Meter (m)
Sensor 5	Sensor 16	Position Y	Meter (m)
Sensor 6	Sensor 17	Position Z	Meter (m)
Sensor 7	Sensor 18	Quaternion W	Scalar
Sensor 8	Sensor 19	Quaternion X	Vector
Sensor 9	Sensor 20	Quaternion Y	Vector
Sensor 10	Sensor 21	Quaternion Z	Vector




Figure 6. Example of ASL "Good" data with 22 parameters.



Figure 7. Examples of VR hand gesture data after applying various padding techniques.

The LSTM-based neural network model, shown in Figure 8, was designed to process the sequential hand gesture data captured in the VR environment. After applying padding techniques, the sequence length was standardized to match the maximum Unity sampling length, which in this case was set to 113 time steps. Each time step in the sequence contains 22 feature dimensions, corresponding to the 22 parameters recorded from both hands during gesture performance.




Figure 8. LSTM-based Neural Network model for VR dataset.

The model architecture begins with a **masking layer** that handles padded values by ignoring them while learning, ensuring that the model only processes relevant data. This layer maintains the input shape of (None, 113, 22), where 113 represents the standardized sequence length and 22 denotes the feature dimensions. The None indicates a variable batch size. The model's core is the LSTM layer, specifically designed to capture the temporal dependencies in the sequential gesture data. The input shape for this layer remains (None, 113, 22), and an additional input (None, 113) represents the mask applied to the sequence. It outputs a

reduced representation with 64 features, highlighting the most significant aspects of the data across the 113 time steps. Finally, the **dense layer** aggregates the information extracted by the LSTM layer, outputting a 10-dimensional vector, where each dimension corresponds to the 10 different hand sign movements during training. This structure ensures the model can effectively classify the input sequences into the correct hand gesture categories.

The LSTM-based model was trained on 800 VR hand gesture samples, with 200 samples reserved for validation. Figures 9 and 10 show the model's performance using different padding techniques.

For the **zero padding technique** (Figure 9), the model demonstrated alignment between training and validation accuracy, indicating effective learning with minimal overfitting. The final accuracy confirmed the model's capability to interpret zero-padded data consistently. **Pre-zero padding** achieved 0.58 validation accuracy, indicating baseline effectiveness but challenges in maintaining data integrity. **Post-zero padding** yielded 0.55 accuracy, with minimal impact from the padding position but some inconsistency in data representation. **Pre- and post-zero padding** was the top-performing zero padding method, with 0.99 accuracy, providing balanced data representation.

Replication padding (Figure 10) also produced promising results, with accuracy and loss curves reflecting consistent learning. This method allowed the model to generalize well from the training data, highlighting the importance of selecting appropriate padding techniques. **Pre-replication padding** excelled with 0.97 accuracy, effectively preserving sequence structure for better model learning. **Post-replication padding** reached 0.73 accuracy, performing better than zero padding but less effectively than Pre-replication Padding. **Pre- and post-replication padding** showed strong results with 0.88 accuracy, demonstrating robustness in maintaining temporal structure.




Figure 9. Training and validation accuracy and loss with zero padding.




Figure 10. Training and validation accuracy and loss with replication padding.

The trained LSTM-based model was comprehensively evaluated using metrics like accuracy, precision, recall, F1 score, and confusion matrix analysis. These metrics provided an overall assessment of the model's performance, helping to identify its general effectiveness in interpreting VR hand gestures.

Figure 11 shows the confusion matrix for the validation dataset, illustrating how well the model predicted each hand sign after training. The matrix indicates strong performance in some categories but also reveals specific hand signs where the model's predictions were less accurate, suggesting potential areas for further refinement.

An additional 100 unseen data samples were tested to assess the model's robustness. Figure 12 presents the confusion matrix for this test dataset, reflecting the model's ability to generalize to new data. These matrices help to understand the model's performance across various categories.

Table 2 summarizes key performance metrics, including accuracy, precision, recall, and F1 score, for both the validation and test datasets. The table also includes an overall ranking of the padding techniques based on these metrics, offering insights into which methods were most effective in ensuring accurate and consistent model performance.




Figure 11. Confusion Matrix for validation dataset.




Figure 12. Confusion Matrix for test dataset (100 new data).

TABLE II
AGGREGATE PERFORMANCE METRICS AND RANKING OF PADDING TECHNIQUES

Padding Technique	Accuracy		Precision		Recall		F1 score		Overall Rank	
	Val.	Test	Val.	Test	Val.	Test	Val.	Test	Val.	Test
Pre-Replication Padding	0.97	0.99	0.98	0.99	0.97	0.99	0.98	0.99	2	1
Pre- and Post-Zero Padding	0.99	0.98	1.00	0.98	0.99	0.98	0.99	0.98	1	2
Pre- and Post-Replication Padding	0.88	0.87	0.88	0.90	0.88	0.87	0.87	0.86	3	3
Post-Replication Padding	0.73	0.67	0.79	0.65	0.73	0.67	0.69	0.61	4	4
Pre-Zero Padding	0.58	0.53	0.53	0.50	0.58	0.53	0.55	0.51	6	5
Post-Zero Padding	0.55	0.50	0.66	0.57	0.55	0.50	0.53	0.49	5	6

The analysis of different padding techniques reveals notable variations in performance metrics, including Accuracy, Precision, Recall, and F1 Score, for both validation and test datasets. These metrics provide a comprehensive view of how each padding technique impacts model performance.

Pre-replication padding shows strong performance across all metrics, achieving high scores in both validation and test datasets. It ranks second in validation and first in the test dataset, indicating its robust ability to generalize and maintain a well-balanced model. The consistently high accuracy, precision, recall, and F1 score suggest that this padding technique minimizes misclassifications effectively and performs reliably across different data splits.

In comparison, **pre- and post-zero padding** achieves perfect precision and high recall in the validation dataset, reflecting its strong performance in identifying positive cases within this controlled environment. However, the technique’s performance slightly drops in the test dataset. This decline may be due to the inherent differences between the validation and test data distributions, which can impact how well the model generalizes to new data. Despite this drop, it remains

highly effective and ranks first in validation and second in the test dataset.

Pre- and post-replication padding ranks third in both datasets, showing stable but not exceptional performance. Although it provides balanced metrics, its scores are lower compared to the top two techniques. This suggests that while it performs reliably, it does not reach the high levels of accuracy and balance achieved by **pre-replication** and **pre- and post-zero padding**.

Post-replication padding ranks fourth, with lower accuracy and F1 score compared to the higher-ranked techniques. This indicates a higher rate of misclassifications and less effective performance overall. The lower metrics suggest that this technique is less capable of managing classification tasks with the same efficiency as the top methods.

Pre-zero and **post-zero padding** exhibit the lowest performance, ranking fifth and sixth, respectively. These techniques show poorer accuracy, precision, and recall, leading to higher misclassification rates. Their lower metrics reflect their limited effectiveness in correctly identifying positive cases and achieving balanced classification results.

Choosing the appropriate padding technique is crucial for optimizing model accuracy and generalization. The top methods, **pre-replication** and **pre- and post-zero padding** offer robust performance and balanced metrics, making them suitable for effective model deployment. Conversely, the lower-ranked techniques highlight areas where model performance could be improved, suggesting their lesser suitability for achieving optimal results.

IV. CONCLUSION

This research highlights the significant influence of padding techniques on the performance of RNN models in interpreting VR hand gesture data. Our findings reveal that selecting an appropriate padding method can lead to substantial improvements in model accuracy, precision, recall, and F1 score, even when utilizing simpler RNN architectures. Specifically, techniques like pre-replication padding and pre- and post-zero padding demonstrate superior effectiveness. Pre-replication padding consistently delivers high performance across all evaluation metrics, maintaining robust accuracy and generalization on both validation and test datasets. Meanwhile, pre- and post-zero padding shows excellent results in the validation phase but exhibits a slight reduction in performance during testing, indicating a potential sensitivity to unseen data.

These results highlight the critical role of selecting appropriate padding techniques to optimize model performance in sequence-based data processing. They demonstrate that even with simpler RNN models, the use of strategic padding can substantially enhance learning efficiency and improve the model's ability to generalize from training data to real-world applications. This emphasizes the need for thoughtful preprocessing choices in the design of sequence models to achieve robust and effective outcomes.

Looking ahead, future research could explore advanced padding strategies to optimize model performance. Investigating the interaction between innovative padding methods and different RNN architectures could unlock opportunities for greater accuracy and efficiency, leading to more effective classification systems in VR and other applications. These padding techniques enhance machine learning models' performance and flexibility in complex VR and real-life scenarios by standardizing data input, improving robustness, optimizing computational efficiency, and enabling cross-domain applications. They can significantly improve applications like sign language to speech conversion by ensuring consistent and accurate data processing, enabling real-time translation of hand gestures captured in VR into speech. This is crucial for developing assistive technologies that empower individuals with speech impairments. As VR technology evolves, these padding strategies will be essential for creating more sophisticated, responsive, and adaptable systems for real-world interactions. Continued refinement and innovation in these techniques will drive the next generation of immersive and accessible technologies.

ACKNOWLEDGMENTS

The authors wish to express their profound gratitude to the Directorate of Research, Technology, and Community Service, Ministry of Education, Culture, Research, and Technology of the Republic of Indonesia, for their generous financial support through the 2024 Fiscal Year Research Program. We are equally grateful to Universitas Budi Luhur for providing essential infrastructure, institutional backing, and an enabling environment that greatly contributed to the successful completion of this study. The support, both financial and technical, has been invaluable in ensuring the research's success.

AUTHORS CONTRIBUTION

Teja Endra Eng Tju: Conceptualization, methodology, formal analysis, supervision, and writing—original draft preparation;

Julaiha Probo Anggraini: Writing—review and editing, and project administration;

Muhammad Umar Shalih: Data curation, investigation, software, and validation;

All authors have read and approved the final version of the manuscript.

COPYRIGHT



This work is licensed under a Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International License.

REFERENCES

- [1] S. D. Sulistyaningrum, R. S. Putri, A. Herawati, and S. Irianto, "Trends of virtual reality for learning empirical evidence from different fields," *Journal of Education and Learning (EduLearn)*, vol. 16, no. 4, pp. 531–541, Nov. 2022, doi: 10.11591/edulearn.v16i4.20648.
- [2] L. Muñoz-Saavedra, L. Miró-Amarante, and M. Domínguez-Morales, "Augmented and virtual reality evolution and future tendency," *Applied Sciences (Switzerland)*, vol. 10, no. 1, 2020, doi: 10.3390/app10010322.
- [3] M. Alizadeh and N. Cowie, "Self-directed learning using VR," *Pacific Journal of Technology Enhanced Learning*, vol. 4, no. 1, pp. 10–11, Feb. 2022, doi: 10.24135/pjtel.v4i1.130.
- [4] H. R. Spero, I. Vazquez-Lopez, K. Miller, R. Joshaghani, S. Cutchin, and J. Enterkine, "Drones, virtual reality, and modeling: communicating catastrophic dam failure," *Int J Digit Earth*, vol. 15, no. 1, pp. 585–605, Dec. 2022, doi: 10.1080/17538947.2022.2041116.
- [5] N. Albertini, J. Baldini, A. Dal Pino, F. Lazzari, S. Legnaioli, and V. Barone, "PROTEUS: an immersive tool for exploring the world of cultural heritage across space and time scales," *Herit Sci*, vol. 10, no. 1, 2022, doi: 10.1186/s40494-022-00708-3.
- [6] G. E. Lysenko, A. V. Shehegolev, B. N. Bogomolov, and D. P. Meshakov, "Virtual reality therapy in patients after trauma surgery: prospective clinical trial," *Annals of Critical Care*, vol. 2023, no. 3, 2023, doi: 10.21320/1818-474X-2023-3-58-65.
- [7] C. P. Kamm, R. Kueng, and R. Blättler, "Development of a new immersive virtual reality (VR) headset-based dexterity training for patients with multiple sclerosis: Clinical and technical aspects,"

- Technology and Health Care*, pp. 1–12, Aug. 2023, doi: 10.3233/THC-230541.
- [8] C. P. Kamm, R. Blättler, R. Kueng, and T. Vanbellinghen, “Feasibility and usability of a new home-based immersive virtual reality headset-based dexterity training in multiple sclerosis,” *Mult Scler Relat Disord*, vol. 71, p. 104525, Mar. 2023, doi: 10.1016/j.msard.2023.104525.
- [9] Z. Jiang, A. Meltzer, and X. Zhang, “Using virtual reality to implement disability studies’ advocacy principles: uncovering the perspectives of people with disability,” *Disabil Soc*, pp. 1–21, Jan. 2023, doi: 10.1080/09687599.2022.2150601.
- [10] A. Tariq, T. Rana, and M. Nawaz, “Virtual Reality for Disabled People: A Survey,” in *2018 12th International Conference on Open Source Systems and Technologies (ICOSST)*, IEEE, Dec. 2018, pp. 17–21. doi: 10.1109/ICOSST.2018.8632182.
- [11] N. R. Rahim and A. A. A. Rahim, “A VIRTUAL REALITY APPROACH TO SUPPORT MALAYSIAN SIGN LANGUAGE INTERACTIVE LEARNING FOR DEAF-MUTE CHILDREN,” *J Pharm Negat Results*, vol. 13, 2022.
- [12] K. Sangeethalakshmi, K. G. Shanthi, A. Mohan Raj, S. Muthuselvan, P. Mohammad Taha, and S. Mohammed Shoaib, “Hand gesture vocalizer for deaf and dumb people,” *Mater Today Proc*, vol. 80, 2023, doi: 10.1016/j.matpr.2021.07.324.
- [13] A. Vaitkevicius, M. Taroza, T. Blažauskas, R. Damaševičius, R. Maskeliunas, and M. Woźniak, “Recognition of American Sign Language gestures in a Virtual Reality using Leap Motion,” *Applied Sciences (Switzerland)*, vol. 9, no. 3, 2019, doi: 10.3390/app9030445.
- [14] A. Shaw *et al.*, “JengASL: A Gamified Approach to Sign Language Learning in VR,” *J WSCG (Plzen)*, vol. 31, no. 1–2, 2023, doi: 10.24132/JWSCG.2023.4.
- [15] G. Park and W. Woo, “Hybrid 3D Hand Articulations Tracking Guided by Classification and Search Space Adaptation,” in *Proceedings of the 2018 IEEE International Symposium on Mixed and Augmented Reality, ISMAR 2018*, 2018. doi: 10.1109/ISMAR.2018.00029.
- [16] F. Wen, Z. Zhang, T. He, and C. Lee, “AI enabled sign language recognition and VR space bidirectional communication using triboelectric smart glove,” *Nat Commun*, vol. 12, no. 1, 2021, doi: 10.1038/s41467-021-25637-w.
- [17] N. Takayama, G. Benitez-Garcia, and H. Takahashi, “Masked Batch Normalization to Improve Tracking-Based Sign Language Recognition Using Graph Convolutional Networks,” in *Proceedings - 2021 16th IEEE International Conference on Automatic Face and Gesture Recognition, FG 2021*, 2021. doi: 10.1109/FG52635.2021.9667007.
- [18] F. Reggiswarashari and S. W. Sihwi, “Speech emotion recognition using 2D-convolutional neural network,” *International Journal of Electrical and Computer Engineering*, vol. 12, no. 6, 2022, doi: 10.11591/ijece.v12i6.pp6594-6601.
- [19] F. Alrasheedi, X. Zhong, and P. C. Huang, “Padding Module: Learning the Padding in Deep Neural Networks,” *IEEE Access*, vol. 11, 2023, doi: 10.1109/ACCESS.2023.3238315.
- [20] X. Hu, X. Wei, Y. Gao, W. Zhuang, M. Chen, and H. Lv, “An attention-mechanism-based traffic flow prediction scheme for smart city,” in *2019 15th International Wireless Communications and Mobile Computing Conference, IWCMC 2019*, 2019. doi: 10.1109/IWCMC.2019.8766639.
- [21] T. E. E. Tju and M. U. Shalih, “Hand Sign Interpretation through Virtual Reality Data Processing,” *Jurnal Ilmu Komputer dan Informasi*, vol. 17, no. 2, pp. 185–194, Jun. 2024, doi: 10.21609/jiki.v17i2.1280.
- [22] “Meta Quest 2: Our Most Advanced New All-in-One VR Headset | Oculus | Meta Store.” Accessed: Aug. 04, 2024. [Online]. Available: <https://www.meta.com/quest/products/quest-2/tech-specs/#tech-specs>
- [23] “Top 10 & 25 American Sign Language Signs for Beginners – The Most Known Top 10 & 25 ASL Signs to Learn First | Start ASL.” Accessed: Aug. 04, 2024. [Online]. Available: <https://www.startasl.com/top-10-25-american-sign-language-signs-for-beginners-the-most-know-top-10-25-asl-signs-to-learn-first/>
- [24] “‘you’ ASL American Sign Language.” Accessed: Aug. 04, 2024. [Online]. Available: <https://www.lifeprint.com/asl101/pages-signs/y/you.htm>
- [25] “‘help’ American Sign Language (ASL).” Accessed: Aug. 04, 2024. [Online]. Available: <https://www.lifeprint.com/asl101/pages-signs/h/help.htm>
- [26] “‘me’ American Sign Language (ASL).” Accessed: Aug. 04, 2024. [Online]. Available: <https://www.lifeprint.com/asl101/pages-signs/m/me.htm>
- [27] “Meta Quest 2: Immersive All-In-One VR Headset | Meta Store | Meta Store.” Accessed: Aug. 04, 2024. [Online]. Available: <https://www.meta.com/quest/products/quest-2/#overview>
- [28] “Unity - Manual: Unity User Manual 2022.3 (LTS).” Accessed: Aug. 04, 2024. [Online]. Available: <https://docs.unity3d.com/Manual/index.html>
- [29] “Unity - Scripting API: CommonUsages.” Accessed: Aug. 04, 2024. [Online]. Available: <https://docs.unity3d.com/ScriptReference/XR.CommonUsages.html>
- [30] “[1808.03314] Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) Network.” Accessed: Aug. 11, 2024. [Online]. Available: <https://arxiv.org/abs/1808.03314>
- [31] A. Sherstinsky, “Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network,” *Physica D*, vol. 404, p. 132306, Mar. 2020, doi: 10.1016/j.physd.2019.132306.
- [32] M. K. Suryadewiansyah and T. E. E. Tju, “Naïve Bayes dan Confusion Matrix untuk Efisiensi Analisa Intrusion Detection System Alert,” *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 8, no. 2, pp. 81–88, 2022, doi: 10.25077/teknosi.v8i2.2022.81-88.

SURAT PERNYATAAN TANGGUNG JAWAB BELANJA

Yang bertanda tangan di bawah ini :

Nama : TEJA ENDRA ENG TJU S.T, M.Kom

Alamat : Alam Sutera Buana III No. 12A

berdasarkan Surat Keputusan Nomor 0459/E5/PG.02.00/2024 dan Perjanjian / Kontrak Nomor 105/E5/PG.02.00.PL/2024; 788/LL3/AL.04/2024; A/UBL/DRPM/000/069/06/24 mendapatkan Anggaran Penelitian Optimalisasi Pengolahan Data VR Isyarat Tangan dengan Teknik Padding Sebesar Rp.41.940.000

Dengan ini menyatakan bahwa :

1. Biaya kegiatan Penelitian di bawah ini meliputi :

No	Uraian	RAB 100%	Realisasi
1	Bahan - ATK: alat tulis utama, peralatan pengukuran, peralatan presentasi, perlengkapan organisasi, peralatan tambahan	Rp.1.033.000	Rp.1.033.000
2	Pengumpulan Data - HR pembantu peneliti - HR pembantu lapangan - Biaya konsumsi - Transport - Uang harian	Rp.10.090.000	Rp.10.090.000
3	Analisis Data - HR pengolah data - Honorarium narasumber - Transport lokal - Uang harian	Rp.10.180.000	Rp.10.180.000
4	Sewa Peralatan - Peralatan penelitian: desktop pengumpulan data - Ruang penunjang penelitian: rapat dan koordinasi - Ruang penunjang penelitian: pengumpulan data - Peralatan penelitian: perangkat VR - Peralatan penelitian: laptop	Rp.11.645.000	Rp.11.645.000
5	Pelaporan Luaran Wajib - Uang harian rapat di luar kantor - Biaya Pendaftaran KI - Biaya konsumsi rapat - Biaya konsumsi rapat - Biaya Publikasi artikel	Rp.8.992.000	Rp.8.992.000
6	Lain-lain	Rp.0	Rp.0
Realisasi (100 %)			Rp.41.940.000

2. Jumlah uang tersebut pada angka 1, benar-benar dikeluarkan untuk pelaksanaan kegiatan Penelitian dimaksud.

Demikian surat pernyataan ini dibuat dengan sebenarnya.



Jakarta, 12-12-2024, Ketua

TEJA ENDRA ENG TJU S.T, M.Kom

NIP/NIPK 190046 - Universitas Budi Luhur