



UNIVERSITATEA DIN PETROȘANI
ȘCOALA DOCTORALĂ
DOMENIUL DE DOCTORAT: INGINERIA SISTEMELOR

REZUMAT TEZĂ DE DOCTORAT

CONDUCĂTOR DE DOCTORAT:
PROF. UNIV. HABIL. DR. ING. LEBA MONICA

STUDENT DOCTORAND:
ING. ZAHA (SĂLĂGEAN) GABRIELA LAURA

ANUL
2025



UNIVERSITATEA DIN PETROȘANI

**ȘCOALA DOCTORALĂ
DOMENIUL DE DOCTORAT:
INGINERIA SISTEMELOR**

**CERCETĂRI PRIVIND RECUNOAȘTEREA AUTOMATĂ A MACRO- ȘI
MICROEXPRESIILOR FACIALE UTILIZÂND METODE DE INTELIGENȚĂ
ARTIFICIALĂ**

**CONDUCĂTOR DE DOCTORAT:
PROF. UNIV. HABIL. DR. ING. LEBA MONICA**

**STUDENT DOCTORAND:
ING. ZAHA (SĂLĂGEAN) GABRIELA LAURA**

**ANUL
2025**

Cuprins

1.Introducere.....	1
1.1 Contextul și fundamentarea cercetării.....	1
1.4 Obiectivele cercetării.....	5
1.5 Contribuții originale.....	6
1.6 Întrebările de cercetare.....	6
1.7 Structura tezei	7
2.Stadiul actual al cercetării.....	9
2.1 Metode tradiționale pentru detecția expresiilor faciale.....	9
2.1.1. Metode bazate pe caracteristici geometrice.....	9
2.1.2. Metode bazate pe aspect (appearance-based method).....	10
2.1.3 Metodele de reducere a dimensionalității.....	11
2.1.4. Clasificatori tradiționali.....	11
2.1.5. Sisteme bazate pe reguli FACS	12
2.2. Abordări bazate pe deep learning.....	14
2.2.1. Arhitecturi CNN pentru emoții.....	14
2.2.2. Arhitecturi pentru secvențe temporale.....	15
2.3. Sisteme de analiză a microexpresiilor.....	16
2.3.1. Metode bazate pe analiza mișcării.....	16
2.3.2. Arhitecturi deep learning pentru microexpresii.....	18
2.4. Metode hibride	18
2.4.1. Combinarea informațiilor geometrice și de aspect.....	19
2.4.2. Combinarea detecției AU cu clasificarea emoțiilor.....	19
2.4.3 Modele LLM (Large Language Model) în recunoașterea emoțiilor	20
2.5. Limitări ale abordărilor existente	21
3. Seturi de date și resurse.....	24
3.1. Setul de date FER2013 pentru expresii faciale	24
3.2 Setul de date CASME2 pentru microexpresii	25
3.3 Setul de date SAMM pentru microexpresii.....	25
3.4 Instrumente și biblioteci software utilizate	26
3.4.1 Python.....	26
3.4.2 OpenCV.....	27
3.4.3. TensorFlow și Keras pentru implementarea CNN.....	28
3.4.4. MediaPipe.....	28
3.4.5 OpenAI	29
3.4.6 Configurația hardware	30
4. Metodologia cercetării	31
4.1. Arhitectura generală a unui sistem de recunoaștere a macroemoțiilor.....	31
4.1.1 Detectarea feței.....	31

4.1.2	Procesarea imaginilor	32
4.1.3	Extragerea caracteristicilor	33
4.1.4	Clasificarea	33
4.2	Clasificatorul Haar	34
4.3	Augmentarea datelor	35
4.2.1.	Funcția Shuffle	35
4.2.2.	Funcția Flip Vertical	36
4.2.3.	Funcția Weighted Loss	36
4.4	Rețele neuronale convoluționale	37
4.5	Algoritmi de optimizare	39
4.6	Sistemul hibrid de detectare a microexpresiilor	40
4.6.1	Arhitectura modelului propus pentru detectarea microexpresiilor	41
4.6.2	Modulul de preprocesare video	42
4.6.3	Detectorul facial bazat pe MediaPipe	43
4.6.4	Sistemul de acțiuni faciale (AU)	44
4.6.5	Modulul bazat pe reguli expert	45
4.6.6	Amplificarea semnalelor de intensitate redusă	47
4.6.7	Ansamblu de clasificare	48
4.7	Metrici pentru evaluare	51
4.7.1	Matricea de confuzie	52
4.7.2	Acuratețea	52
4.7.3	Precizia	53
4.7.4	Recall sau sensibilitate	54
4.7.5	Scorul F1	54
5.	Eperimente	56
5.1.	Protocolul experimental	56
5.1.1	Obiectivele experimentelor	56
5.2	Dezvoltarea modelului CNN personalizat, valorificarea simetriei și abordarea asimetriei în recunoașterea emoțiilor faciale	57
5.2.1.	Utilizarea FER2013 în recunoașterea macroemoțiilor	57
5.2.2	Preprocesarea datelor	59
5.2.3.	Arhitectura rețelei CNN propusă	60
5.2.4	Implementarea arhitecturii propuse în timp real	66
5.3	Modelul Hibrid	67
6.	Rezultate și analiza rezultatelor	69
6.1	Analiza performanței modelului CNN propus	69
6.1.1	Matricea de confuzie	69
6.1.2	Analiza preciziei	74
6.1.3	Analiza Recall-ului	79
6.1.4	Analiza Scor F1	83
6.1.5	Testarea modelului CNN în timp real	86
6.2	Analiza performanței modelului hibrid propus	87

6.2.1 Analiza performanței modelului hibrid pe baza de date CASME II	88
6.2.2 Analiza performanței modelului hibrid pe baza de date SAMM.....	94
7. Discuții.....	97
7.1 Modelului CNN propus pentru macroexpresii.....	97
7.2 Performanța sistemului hibrid pentru microexpresii.....	100
8 Limitări și direcții viitoare de cercetare	107
8.1 Limitări ale Modelului CNN	107
8.2 Limitări ale modelului hibrid	107
8.3 Direcții viitoare de cercetare	107
9 Concluzii.....	113
9.1. Arhitectura și implementarea CNN personalizată.....	116
9.2. Concluzii privind modelul hibrid propus	117
9.3. Contribuții teoretice	119
9.4. Preocupări etice.....	119
9.5 Aplicații practice și impactul cercetării.....	119
9.5.1. Aplicații în educație și instruire.....	119
9.5.2. Aplicații în sănătate și terapie.....	120
9.5.3. Aplicații în securitate și siguranță	121
9.5.4. Aplicații în interacțiunea Om-Computer	121
Bibliografie	123
Anexa 1 Abrevieri.....	138
Anexa 2 Lista figurilor.....	140
Anexa 3 Lista tabelelor	141

Teza de doctorat cu titlul "Cercetări privind recunoașterea automată a macro- și microexpresiilor faciale utilizând metode de inteligență artificială" abordează un domeniu de cercetare interdisciplinar aflat la intersecția dintre psihologie, neuroștiințe și inteligența artificială.

Expresiile faciale sunt expresii universale ale emoțiilor umane și care joacă un rol fundamental în comunicarea nonverbală. Dezvoltarea sistemelor capabile să recunoască și să interpreteze aceste expresii în mod automat are implicații majore în domenii precum interacțiunea om-calculator, securitate, educație și sănătate.

Dezvoltarea tehnologiilor de recunoaștere a expresiilor faciale s-a accelerat considerabil în ultimii ani, fiind susținută de progresele din domeniile inteligenței artificiale, învățării profunde și viziunii computerizate.

Cu toate acestea, domeniul se confruntă încă cu provocări majore, în ceea ce privește detectarea și interpretarea precisă a macroexpresiilor (manifestări emoționale evidente, cu intensitate ridicată și durată mai lungă), cât și în recunoașterea microexpresiilor (manifestări discrete și tranzitorii care apar pentru perioade extrem de scurte și care pot dezvălui emoții ascunse sau suprimate).

Teza de doctorat urmărește fluxul natural al procesului de cercetare științifică, progresând metodic de la fundamentele teoretice, prin metodologia aplicată și experimentele desfășurate, până la rezultatele obținute și concluziile finale. Organizarea tezei reflectă atât complexitatea domeniului abordat, cât și metodologia riguroasă aplicată pentru atingerea obiectivelor propuse.

Obiective principale urmărite:

- a. Valorificarea simetriei și abordarea asimetriei în expresiile faciale pentru îmbunătățirea performanței algoritmilor de recunoaștere a emoțiilor.
- b. Dezvoltarea și validarea unui model CNN personalizat în timp real pentru recunoașterea eficientă a emoțiilor faciale, adaptat pentru a gestiona variabilitatea și asimetria expresiilor.
- c. Dezvoltarea unui cadru teoretic comprehensiv pentru recunoașterea facială, integrând teoria psihologică a expresiilor faciale (FACS) cu abordările tehnologice moderne.
- d. Implementarea unui sistem robust pentru detectarea și clasificarea microexpresiilor faciale în timp real, combinând tehnici tradiționale de computer vision cu algoritmi avansați de machine learning.
- e. Rezolvarea problemelor specifice de confuzie între emoțiile similare prin reguli expert și amplificarea caracteristicilor distinctive.
- f. Evaluarea riguroasă a performanței sistemelor dezvoltate utilizând metrice standard și compararea cu metodele existente.

1. Introducere

Teza debutează cu un capitol introductiv care stabilește cadrul conceptual și metodologic al cercetării. Acesta prezintă contextul științific actual în domeniul recunoașterii expresiilor faciale, subliniind importanța și actualitatea temei în era digitală contemporană. Sunt evidențiate provocările majore cu care se confruntă cercetătorii în acest

domeniu, de la variabilitatea expresiilor faciale în funcție de factorii culturali și individuali, până la dificultățile tehnice legate de achiziția și procesarea imaginilor faciale în condiții reale. Motivația care stă la baza acestei cercetări este prezentată în detaliu, subliniind potențialul aplicativ vast al sistemelor automate de recunoaștere a expresiilor faciale în domenii precum sănătatea mentală, securitatea, educația și interacțiunea om-calculator. O atenție deosebită este acordată distincției între macroexpresii și microexpresii. Această distincție fundamentală constituie una dintre contribuțiile originale ale cercetării, prin propunerea unor abordări diferențiate pentru cele două tipuri de expresii.

Prima abordare vizează recunoașterea macroexpresiilor faciale prin propunerea unui model bazat pe rețele neuronale convoluționale cu accent pe evaluarea impactului tehnicilor de augmentare a datelor, folosind setul de date FER-2013 și implementarea modelului în timp real.

A doua abordare constă într-un sistem hibrid dedicat analizei microexpresiilor faciale, care integrează tehnici avansate de computer vision, reguli expert fundamentate pe sistemul FACS și algoritmi de inteligență artificială. Acest sistem a fost implementat în timp real și testat pe bazele de date CASME II și SAMM.

Întrebările de cercetare care ghidează întregul demers științific, Sunt formulate în mod clar și explicit stabilind astfel direcțiile principale de investigație și criteriile de evaluare a rezultatelor.

Cercetarea a fost ghidată de următoarele întrebări fundamentale:

1. Care sunt cele mai eficiente tehnici și algoritmi pentru recunoașterea facială și detecția emoțiilor în diverse contexte și condiții?
2. Cum poate fi valorificată și abordată simetria facială pentru a îmbunătăți performanța sistemelor de recunoaștere a emoțiilor?
3. Cum pot fi optimizate rețelele neuronale convoluționale pentru a gestiona eficient provocările specifice recunoașterii emoțiilor faciale, luând în considerare dezechilibrul între clase și variabilitatea expresiilor?
4. În ce măsură poate o abordare hibridă, combinând tehnici avansate de computer vision, reguli expert bazate pe sistemul Facial Action Coding System (FACS) și algoritmi de inteligență artificială, să îmbunătățească detecția microexpresiilor faciale?
5. Care sunt cele mai eficiente strategii pentru diferențierea între emoții similare din punct de vedere al expresiilor faciale?

2. Stadiul actual al cercetării

Acest capitol oferă o analiză comprehensivă și critică a literaturii de specialitate, evidențiind evoluția metodelor și tehnicilor de recunoaștere a expresiilor faciale de-a lungul timpului. Acesta începe cu o incursiune istorică în dezvoltarea teoriilor emoțiilor și a expresiilor faciale, pornind de la lucrările fundamentale ale lui Charles Darwin și Paul Ekman, care au stabilit baza conceptuală a universalității anumitor expresii emoționale. Sunt prezentate metodele tradiționale de recunoaștere a expresiilor faciale, bazate pe extragerea manuală a trăsăturilor și utilizarea clasificatorilor clasici. Evoluția cronologică a domeniului

este urmărită prin prezentarea trecerii spre abordările bazate pe învățare automată, cu accent pe apariția și dezvoltarea rețelelor neuronale convoluționale (CNN) care au revoluționat domeniul recunoașterii vizuale a patternurilor. Sunt analizate comparativ diverse arhitecturi CNN care au fost aplicate cu succes în domeniul recunoașterii expresiilor faciale, precum VGG, ResNet, Inception și EfficientNet, evidențiind avantajele și limitările fiecăreia.

O secțiune substanțială este dedicată metodelor specializate pentru detectarea și recunoașterea microexpresiilor. Sunt prezentate tehnicile de analiză a mișcării bazate pe flux optic, magnification video și analiza temporală a schimbărilor faciale, care sunt esențiale pentru captarea microexpresiilor.

Capitolul include, de asemenea, o analiză a sistemelor hibride care combină diverse abordări pentru îmbunătățirea performanțelor de recunoaștere, precum și a potențialului modelelor LLM în interpretarea contextului emoțional. Analiza literaturii de specialitate se încheie cu identificarea clară a limitărilor actuale ale sistemelor existente, creând astfel premisele pentru contribuțiile originale propuse în cadrul tezei.

3. Seturi de date și resurse

Baza de date FER2013 (Facial Emotion Recognition 2013) este analizată în detaliu, fiind alcătuită din peste 35.000 de imagini faciale în nunațe de gri, distribuite în șapte categorii emoționale: fericire, tristețe, frică, furie, dezgust, surpriză și neutralitate. Sunt discutate avantajele acestei baze de date, cum ar fi volumul mare de imagini și diversitatea condițiilor de captare, dar și limitările sale legate de dezechilibrul între clase și rezoluția relativ scăzută a imaginilor.

Pentru studiul microexpresiilor, sunt prezentate două baze de date specializate: CASME II (Chinese Academy of Sciences Micro-Expression Database II) și SAMM (Spontaneous Actions and Micro-Movements). CASME II este o colecție de 255 de microexpresii capturate la o rată ridicată de cadre pe secundă (200 fps), clasificate în cinci clase emoționale principale, în timp ce SAMM oferă 159 de microexpresii capturate la 200 fps, cu o diversitate demografică mai mare. În Capitolul continuă cu descrierea detaliată a instrumentelor software și hardware folosite pentru dezvoltarea sistemului propus. Sunt prezentate bibliotecile Python specializate pentru procesarea imaginilor și învățare profundă, cum ar fi OpenCV pentru manipularea imaginilor, TensorFlow și Keras pentru implementarea rețelelor neuronale, MediaPipe pentru detectarea și urmărirea punctelor de reper faciale, precum și tehnologiile OpenAI pentru aspectele legate de integrarea modelelor lingvistice. Specificațiile hardware utilizate pentru antrenarea și testarea modelelor sunt, de asemenea, detaliate, subliniind importanța resurselor computaționale adecvate pentru procesarea eficientă a algoritmilor de învățare profundă.

Nu în ultimul rând este prezentată configurația hardware utilizată. Un sistem de calul cu un procesor Intel Core i7-10700K, 32GB de RAM DDR4, SSD 1TB și o placă NVIDIA GeForce RTX 3080, 10GB RAM.

4. Metodologia cercetării

Constituie nucleul conceptual al tezei de doctorat, detaliind arhitecturile generale a sistemului de identificare a emoțiilor dezvoltate. Capitolul începe cu prezentarea cadrului metodologic general, bazat pe principiile învățării profunde și pe analiza morfologică a expresiilor faciale. Este explicată abordarea diferențiată adoptată pentru macroexpresii și microexpresii, justificată prin natura distinctă a acestor două tipuri de manifestări emoționale.

Pentru macroexpresii, este prezentată în detaliu arhitectura modelului bazat pe rețele neuronale convoluționale (CNN), începând cu structura straturilor convoluționale, funcțiile de activare utilizate și mecanismele implementate pentru prevenirea overfitting-ului. Sunt explicate motivațiile din spatele fiecărei decizii arhitecturale, cum ar fi alegerea dimensiunii filtrelor, a strategiilor de pooling și a organizării straturilor dense finale. O atenție deosebită este acordată metodelor de preprocesare a imaginilor faciale, care includ detectarea feței, normalizarea și augmentarea datelor.

Pentru sistemul dedicat microexpresiilor, este prezentată arhitectura hibridă dezvoltată, care combină analiza temporală a secvențelor video cu extragerea trăsăturilor spațiale. Sunt detaliate tehnicile utilizate pentru amplificarea mișcărilor subtile ale mușchilor faciali, precum și metodele de analiză pentru captarea dinamicii temporale a microexpresiilor. O contribuție semnificativă prezentată în acest capitol este procesul de integrare a modelelor lingvistice de mari dimensiuni (LLM), specific GPT-3.5-turbo, în fluxul de procesare pentru gestionarea situațiilor ambigue în care clasificarea bazată pe reguli nu oferă o decizie concludentă. Acest proces implică generarea automată a unui prompt structurat incluzând lista unităților de acțiune detectate, regulile explicite de clasificare și informații contextuale; procesarea promptului de către modelul LLM; validarea răspunsului prin verificarea conformității cu regulile și constrângerile definite în sistem; și aplicarea regulilor de corecție și filtrare pentru eventualele răspunsuri eronate sau inconsistente.

Capitolul include, de asemenea, descrierea algoritmilor de segmentare facială utilizați pentru izolarea regiunilor de interes relevante pentru expresiile emoționale, implementarea modulelor de analiză a asimetriei faciale, metodologia de antrenare a modelelor, incluzând strategiile de optimizare, funcțiile de pierdere utilizate, tehnicile de ajustare a hiperparametrilor și metricile de evaluare utilizate (matricea de confuzie, precizia, recall-ul și scorul F1).

5. Experimente

Partea experimentală a tezei de doctorat detaliază protocoalele de testare și evaluare a modelelor propuse. Capitolul debutează cu prezentarea metodologiei experimentale generale, accentuând importanța validării încrucișate în vederea obținerii unor estimări robuste și fiabile ale performanței sistemului propus. În cadrul studiului au fost realizate șase

experimente distincte, orientate spre analiza eficienței rețelei neuronale convoluționale (CNN) în recunoașterea macroexpresiilor faciale și testate pe baza de date FER2013. Fiecare experiment a testat o configurație diferită a procesului de antrenare:

- Cazul 1: Rețeaua CNN a fost antrenată utilizând funcția Shuffle.
- Cazul 2: Rețeaua CNN a fost antrenată utilizând funcția Shuffle și funcția Flip Vertical.
- Cazul 3: Rețeaua CNN a fost antrenată utilizând funcția Loss Weight.
- Cazul 4: Rețeaua CNN a fost antrenată utilizând funcția Shuffle și funcția Loss Weight.
- Cazul 5: Rețeaua CNN a fost antrenată utilizând o configurație complexă, care a integrat simultan funcțiile Flip Vertical, Shuffle și Loss Weight.
- Cazul 6: Rețeaua CNN a fost antrenată utilizând funcția Shuffle, însă s-a introdus o modificare suplimentară prin creșterea dimensiunii lotului de testare.

Procesul de antrenare a rețelei neuronale convoluționale (CNN) este descris în detaliu, incluzând strategiile de inițializare a ponderilor, algoritmi de optimizare utilizați precum și tehnicile de normalizare a datelor. Aceste elemente au fost esențiale pentru a preveni supraînvățarea și pentru a asigura o generalizare eficientă a modelului. De asemenea, sunt prezentate modalitățile de ajustare a hiperparametrilor, precum rata de învățare, dimensiunea lotului (batch size) și numărul de epoch.

De asemenea, a fost descrisă implementarea în timp real a modelului CNN propus, pentru a evalua capacitatea acestuia de a funcționa eficient într-un mediu aplicativ.

Pentru experimentele cu microexpresii sunt detaliate procedurile de extracție a secvențelor relevante din înregistrările video, sincronizarea cadrelor și tehnicile de amplificare aplicate.

Testarea sistemului hibrid s-a realizat pe bazele de date CASME II și SAMM și a urmărit :

- Acuratețea detecției unităților de acțiune facială în raport cu adnotările manuale din bazele de date;
- Eficiența regulilor expert în clasificarea microexpresiilor;
- Eficacității integrării modelului LLM în rezolvarea cazurilor ambigue;
- Performanța globală a sistemului hibrid în condiții de funcționare în timp real.

6. Rezultate și analiza rezultatelor

Rezultatele obținute în urma experimentelor sunt analizate riguros și performanțele modelelor propuse sunt interpretate utilizând o serie de metrici standardizate precum matricea de confuzie acuratețea globală, precizia, sensibilitatea (recall) și scorul F1.

Capitolul este structurat în două secțiuni principale: analiza performanței modelului CNN propus și analiza performanței modelului hibrid propus.

Prima secțiune evaluează performanța rețelei neuronale convoluționale (CNN) propuse pentru clasificarea macroexpresiilor faciale. Modelul a fost testat în șase configurații

experimentale diferite, utilizând diverse strategii de augmentare a datelor descries în capitolul anterior. Acuratețea globală a modelului este de 92%.

Matricile de confuzie generate pentru cele șase cazuri experimentale au evidențiat performanțe ridicate ale modelului propus pe fiecare clasă de emoție. Sunt evidențiate clasele emoționale care prezintă confuzii frecvente, cum ar fi frica și surprins sau tristețe și neutru (lipsa stării emoționale).

Analiza preciziei pe fiecare clasă emoțională a relevat (Tabelul 6.1): performanță ridicată pentru emoțiile distincte precum fericirea (>90%), precizie bună pentru clasa de emoții neutru și surprins (>75%), provocări în clasificarea precisă a emoțiilor similare precum frica și tristețea și influența semnificativă a tehnicilor de augmentare asupra preciziei pentru anumite clase emoționale.

Tabel 6.1 Precizia (%) pe fiecare emoție în cele 6 cazuri

Emoție	Cazul 1	Cazul 2	Cazul 3	Cazul 4	Cazul 5	Cazul 6
furie	0.88	0.88	0.88	0.89	0.88	0.90
dispreț	0.95	0.99	0.97	0.84	0.94	0.98
frică	0.89	0.92	0.89	0.90	0.90	0.85
fericire	0.96	0.94	0.95	0.96	0.95	0.94
neutru	0.88	0.89	0.91	0.87	0.87	0.87
tristețe	0.88	0.89	0.88	0.87	0.89	0.86
surprinză	0.95	0.95	0.92	0.95	0.93	0.87

Analiza recall-ului pe fiecare clasă emoțională a arătat (tabelul 6.2): recall ridicat pentru fericire și expresii neutre, valori moderate pentru surprins și furie, provocări în detectarea completă a instanțelor de frică și dispreț, variații semnificative ale recall-ului în funcție de tehnicile de augmentare utilizate.

Tabel 6.2 Recall pe fiecare emoție în cele 6 cazuri

Emoție	Cazul 1	Cazul 2	Cazul 3	Cazul 4	Cazul 5	Cazul 6
furie	0.86	0.88	0.89	0.89	0.88	0.92
dispreț	0.87	0.88	0.86	0.89	0.88	0.90
frică	0.88	0.88	0.90	0.88	0.87	0.82
fericire	0.95	0.96	0.94	0.94	0.94	0.95
neutru	0.93	0.91	0.91	0.92	0.93	0.89
tristețe	0.88	0.88	0.88	0.88	0.86	0.82
surprinză	0.94	0.95	0.94	0.94	0.94	0.88

Scorul F1 a oferit o perspectivă echilibrată asupra performanței modelului (Tabelul 6.3): scoruri F1 ridicate pentru fericire (>85%), valori bune pentru clasa de emoții neutru și surprins, scoruri moderate pentru furie și valori mai scăzute pentru frică și dispreț.

Tabel 6.3 Scor F1 pe fiecare emoție în cele 6 cazuri

Emoție	Cazul 1	Cazul 2	Cazul 3	Cazul 4	Cazul 5	Cazul 6
Furie	0.88	0.88	0.89	0.89	0.88	0.91
Dispreț	0.91	0.93	0.91	0.92	0.91	0.94
Frică	0.88	0.90	0.89	0.89	0.89	0.83
Fericire	0.96	0.95	0.95	0.95	0.94	0.94
Neutru	0.90	0.90	0.91	0.89	0.90	0.88
Tristețe	0.88	0.89	0.88	0.87	0.88	0.84
Uimire	0.94	0.95	0.93	0.94	0.94	0.87

Un aspect semnificativ al rezultatelor este reprezentat de consistența scorurilor F1 în toate cele șase configurații experimentale, ceea ce reflectă stabilitatea operațională a modelului în fața variabilității externe.

Implementarea în timp real a modelului CNN a demonstrat capacitatea sistemului de a funcționa eficient în condiții practice, cu o rată de procesare de peste 25 de cadre pe secundă.

A doua secțiune evaluează performanța modelului hibrid propus pentru microexpresii. La testarea pe baza de date CASME II precizia obținută a fost de 93,3% , iar pe SAMM 98,4%. Testarea modelului hibrid a evidențiat eficiența mecanismului de integrare LLM în rezolvarea cazurilor ambigue, și robustețea clasificării în fața variabilității expresiilor între subiecți diferiți. Sunt evaluate dificultățile particulare întâmpinate în detectarea diferitelor tipuri de microexpresii, corelându-le cu aspecte fiziologice ale mușchilor faciali implicați. Rezultatele obținute în urma implementării în timp real au validat robustețea și aplicabilitatea practică a sistemului propus

Capitolul abordează, de asemenea, efectele dezechilibrelor de clasă asupra performanțelor de recunoaștere. Sunt analizate în detaliu cazurile de confuzie emoțională, corelându-le cu teoriile psihologice privind similaritățile și suprapunerile între anumite expresii emoționale, precum și cu limitările inerente ale reprezentărilor vizuale pentru captarea întregului spectru emoțional uman.

7. Discuții

Discuțiile integrate în acest capitol plasează rezultatele obținute în contextul mai larg al literaturii de specialitate, evidențiind contribuțiile originale ale tezei de doctorat.

Principalele puncte forte ale modelului CNN propus pentru macroexpresii sunt:

- Valorificarea optimă a simetriei faciale pentru îmbunătățirea clasificării
- Tehnicile de augmentare a datelor au avut un impact semnificativ asupra robusteții modelului, reducând supraantrenarea și îmbunătățind capacitatea de generalizare a modelului propus.

- Eficiența computațională - modelul atinge un echilibru între complexitate și performanță, fiind optimizat pentru utilizare în timp real
- Robustețea în fața variațiilor - capacitatea de a gestiona variații de iluminare, poziționare și expresivitate individuală
- Acuratețea clasificării - performanțe competitive (aproximativ 90-91%) pe setul FER2013, în comparație cu alte modele din literatura de specialitate
- Implementarea practică - funcționalitate demonstrată în condiții de operare în timp real

Sistemul hibrid propus pentru detecția microexpresiilor reprezintă o contribuție semnificativă în domeniu, oferind:

- O abordare modulară care îmbunătățește transparența și controlul asupra fluxului decizional
- Flexibilitate în adaptarea la seturi de date dezechilibrate - eficiență îmbunătățită în gestionarea claselor minoritare și a expresiilor rare sau atipice
- Rezolvarea eficientă a ambiguităților între emoții similare (ex. frică-surprins sau tristețe-dispreț)
- Integrarea inovatoare a modelelor LLM pentru îmbunătățirea procesului decizional abordarea hibridă care combină detecția automată a unităților de acțiune (AU) cu clasificarea realizată prin intermediul unui model LLM (GPT-3.5-turbo)
- Performanțe superioare – precizie de 93.3 pe baza de date CASME II și de 98,46% pe baza de date SAMM, reprezentând un avans semnificativ față de metodele tradiționale

8. Limitări și direcții viitoare de cercetare

Se prezintă o analiză critică a limitărilor identificate în cadrul modelelor dezvoltate și se propun direcții de cercetare.

În ceea ce privește modelul CNN propus pentru recunoașterea macroexpresiilor, principalele limitări identificate includ:

- Utilizarea setului de date FER2013 care prezintă un dezechilibru între clase, afectează performanța modelului în recunoașterea emoțiilor minim reprezentate, cum ar fi disprețul și uimirea.
- Dependența de imaginile în tonuri de gri limitează aplicabilitatea modelului în timp real, unde datele sunt colorate și pot include variații naturale de lumină și contrast.
- Testarea pe un număr limitat de subiecți poate limita generalizarea modelului la o populație mai largă și diversă din punct de vedere cultural și demografic.
- Sensibilitatea la variațiile de iluminare și poziție a feței rămâne o provocare, în pofida tehnicilor de augmentare implementate, putând influența negativ performanța sistemului în contexte necontrolate.

În ceea ce privește sistemul hibrid pentru recunoașterea microexpresiilor, limitările principale includ:

- Dependența de calitatea detecției inițiale a unităților de acțiune poate afecta întregul pipeline de clasificare, introducând erori care se propagă în sistem.
- Variabilitatea culturală și demografică în exprimarea microexpresiilor nu a fost pe deplin testată în modelul actual, ceea ce poate limita aplicabilitatea sa universală.
- Necesitatea resurselor computaționale semnificative pentru rularea modelului hibrid poate reprezenta o barieră pentru implementarea în dispozitive cu resurse limitate sau în aplicații care necesită procesare edge computing.
- Provocările etice și de confidențialitate asociate cu recunoașterea emoțiilor în timp real rămân aspecte importante care necesită o abordare responsabilă în dezvoltarea și implementarea sistemelor bazate pe aceste tehnologii.

Principalele direcții de dezvoltare viitoare ca urmare a analizării rezultatelor obținute și a limitărilor identificate în cadrul studiului sunt:

- Sisteme multi-modale care combină analiza expresiilor faciale cu alte modalități precum (voce, gesturi)
- Arhitecturi adaptative personalizate pentru utilizatori individuali, capabile să se adapteze la specificul expresiv al fiecărui individ, prin tehnici de calibrare și transfer learning
- Sisteme explicabile și transparente (XAI) pentru interpretarea deciziilor modelelor
- Abordări contextuale care integrează factori situaționali în recunoașterea emoțiilor
- Extensii pentru aplicații specifice în educație, sănătate și Securitate
- Explorarea implicațiilor etice.

9. Concluzii generale

Acest capitol sintetizează principalele contribuții și realizări ale tezei de doctorat, oferind o perspectivă integrată asupra implicațiilor teoretice și practice. Sunt recapitulate obiectivele inițiale și modul în care acestea au fost îndeplinite prin metodologia propusă și rezultatele obținute.

Primul obiectiv al cercetării a vizat explorarea modului în care simetria facială poate fi valorificată pentru îmbunătățirea performanței algoritmilor de recunoaștere a emoțiilor. S-a demonstrat că simetria facială joacă un rol important în recunoașterea corectă a emoțiilor, iar asimetria – fie cea naturală, fie cea indusă de factori emoționali – poate afecta semnificativ acuratețea clasificării.

Aceste tehnici au contribuit la o interpretare mai nuanțată și precisă a emoțiilor exprimate, ducând la o îmbunătățire semnificativă a acurateței algoritmilor de recunoaștere, care a atins 92%.

Al doilea obiectiv a vizat dezvoltarea și validarea unui model CNN capabil să funcționeze în timp real și să gestioneze eficient variabilitatea și asimetria expresiilor faciale. Acest obiectiv a fost îndeplinit prin proiectarea și implementarea unei arhitecturi CNN personalizate, optimizată pentru recunoașterea emoțiilor faciale în condiții diverse de iluminare, unghi și variabilitate individuală.

Implementarea acestui model a confirmat eficacitatea abordării propuse, subliniind potențialul său pentru aplicații în timp real în domenii precum interacțiunea om-computer, securitate sau analiză comportamentală.

Al treilea obiectiv a vizat elaborarea unui cadru teoretic comprehensiv care să integreze teoriile psihologice ale expresiilor faciale cu abordările tehnologice moderne. Acest obiectiv a fost realizat prin dezvoltarea unei baze conceptuale solide care combină sistemul FACS (Facial Action Coding System) cu tehnicile avansate din domeniul machine learning și computer vision.

Această integrare a permis o abordare mai holistică în studierea expresiilor faciale, facilitând atât analizarea emoțiilor, cât și dezvoltarea algoritmilor capabili să interpreteze aceste expresii în mod eficient și nuanțat.

Al patrulea obiectiv a vizat implementarea unui sistem robust pentru detectarea și clasificarea microexpresiilor faciale în timp real. Acest obiectiv a fost îndeplinit prin dezvoltarea sistemului hibrid care combină tehnici tradiționale de computer vision cu algoritmi avansați de machine learning și inteligență artificială.

Acest sistem nu doar că facilitează o detectare rapidă a emoțiilor discrete, dar asigură și o clasificare precisă în timp real, oferind aplicații promițătoare în domenii precum psihologie și securitate.

Al cincilea obiectiv a vizat abordarea problemelor specifice de confuzie între emoții similare prin implementarea unor reguli expert și amplificarea caracteristicilor distinctive. Acest obiectiv a fost realizat prin dezvoltarea unor mecanisme specializate pentru diferențierea între emoții frecvent confundate, precum fericirea și surpriza sau tristețea și frica.

Aceste reguli au fost integrate în procesul de clasificare, permițând sistemului să diferențieze între emoții adesea confundate și să ofere rezultate precise, contribuind la atingerea unei acuratețe de 93.3% pe setul de date CASME II.

Al șaselea obiectiv a vizat evaluarea riguroasă a performanței sistemelor dezvoltate utilizând metrici standard și compararea cu metodele existente. Acest obiectiv a fost îndeplinit prin realizarea unei evaluări detaliate și comprehensivă a sistemelor propuse, utilizând metricile standard din domeniu și raportând rezultatele în raport cu cele mai performante metode existente.

Rezultatele acestei evaluări au confirmat îmbunătățirile semnificative aduse de abordările propuse, stabilind o bază solidă pentru implementarea ulterioară și adoptarea acestor tehnologii în aplicații practice.

Diseminarea rezultatelor obținute în cadrul acestei teze de doctorat s-a realizat prin publicarea a două lucrări științifice în cadrul conferințelor internaționale (ITEMA 2023 și ICIE 2025) și a două articole științifice în reviste internaționale de prestigiu, indexate Web of Science, contribuind la vizibilitatea și validarea contribuțiilor aduse în domeniu.

Astfel, articolul intitulat "Face Recognition: A Literature Review", prezentat la 7th International Scientific Conference ITEMA 2023 [203], oferă o sinteză extinsă a tehnicilor de recunoaștere facială, analizând evoluția algoritmilor de la metodele tradiționale la soluțiile bazate pe rețele neuronale convoluționale.

De asemenea, lucrarea "Origami Complexity Decoded: Leveraging SqueezeNet for Image Classification", publicată în volumul *Innovations in Mechatronics Engineering IV* (Springer Lecture Notes in Mechanical Engineering), în urma participării la conferința ICIE 2025 [204], propune o abordare inovatoare de clasificare a imaginilor, utilizând arhitecturi de tip SqueezeNet pentru optimizarea proceselor de recunoaștere vizuală în contexte complexe.

Articolul intitulat "Leveraging Symmetry and Addressing Asymmetry Challenges for Improved Convolutional Neural Network-Based Facial Emotion Recognition", publicat în revista *Symmetry* [135], prezintă o abordare inovatoare ce propune valorificarea simetriei în recunoașterea emoțiilor faciale utilizând o rețea neuronală convoluțională personalizată. De asemenea, soluția dezvoltată a fost integrată și validată într-o aplicație de recunoaștere a emoțiilor faciale în timp real, demonstrând astfel fezabilitatea implementării în contexte practice.

Articolul "Seeing the Unseen: Real-Time Micro-Expression Recognition with Action Units and GPT-Based Reasoning", publicat în revista *Applied Sciences* [182], propune un sistem avansat de recunoaștere a microexpresiilor în timp real, integrând modele bazate pe unități de acțiune facială și algoritmi de raționament bazat pe modele LLM (GPT-3.5-turbo).

Aceste contribuții au permis valorificarea și diseminarea rezultatelor cercetării în cadrul comunității științifice internaționale, facilitând schimbul de idei, dezbaterile soluțiilor propuse și validarea metodologiilor dezvoltate prin evaluare de specialitate.

Publicarea acestor lucrări atestă relevanța științifică a cercetării desfășurate în cadrul tezei de doctorat și contribuie la extinderea frontierelor cunoașterii în domeniul recunoașterii automate a macro și micro expresiilor faciale.

Totodată, teza aduce în prim-plan implicațiile etice asociate acestor tehnologii, subliniind importanța utilizării lor într-un mod responsabil, cu respectarea drepturilor fundamentale ale individului, a intimității și a autonomiei personale.

De asemenea, este analizată aplicabilitatea modelelor propuse în contexte reale, precum cel medical, educațional și al securității, punându-se accent pe impactul social și pe potențialul acestora de a genera beneficii semnificative.

În concluzie, teza de doctorat contribuie semnificativ la domeniul recunoașterii micro și macroexpresiilor, propunând abordări inovative pentru tratarea diferențiată a macroexpresiilor și microexpresiilor, și deschizând noi perspective pentru dezvoltarea sistemelor inteligente cu capacități avansate de percepție și interpretare a emoțiilor umane..

Bibliografie

1. Jack, R.E.; Schyns, P.G. The Human Face as a Dynamic Tool for Social Communication. *Current Biology* **2015**, *25*, R621–R634, doi:10.1016/j.cub.2015.05.052.
2. Sinha, P.; Balas, B.; Ostrovsky, Y.; Russell, R. Face Recognition by Humans: Nineteen Results All Computer Vision Researchers Should Know About. *Proc. IEEE* **2006**, *94*, 1948–1962, doi:10.1109/JPROC.2006.884093.

3. Darwin C. R. *The Expression of the Emotions in Man and Animals*; 1st edition.; John Murray: London, UK, 1872;
4. Ekman, P.; Friesen, W.V. Constants across Cultures in the Face and Emotion. *Journal of Personality and Social Psychology* **1971**, *17*, 124–129, doi:10.1037/h0030377.
5. Ekman, P.; Friesen, W.V. The Repertoire of Nonverbal Behavior: Categories, Origins, Usage, and Coding. *Semiotica* **1969**, *1*, 49–98, doi:10.1515/semi.1969.1.1.49.
6. Ekman, P.; Friesen, W.V. Facial Action Coding System. **2019**, doi:10.1037/t27734-000.
7. Ekman, P.; Friesen, W.V. Nonverbal Leakage and Clues to Deception[†]. *Psychiatry* **1969**, *32*, 88–106, doi:10.1080/00332747.1969.11023575.
8. Haggard, E.A.; Isaacs, K.S. Micromomentary Facial Expressions as Indicators of Ego Mechanisms in Psychotherapy. In *Methods of Research in Psychotherapy*; Springer US: Boston, MA, 1966; pp. 154–165 ISBN 978-1-4684-6047-6.
9. Porter, S.; Ten Brinke, L. Reading Between the Lies: Identifying Concealed and Falsified Emotions in Universal Facial Expressions. *Psychol Sci* **2008**, *19*, 508–514, doi:10.1111/j.1467-9280.2008.02116.x.
10. Zhao, W.; Chellappa, R.; Phillips, P.J.; Rosenfeld, A. Face Recognition: A Literature Survey. *ACM Comput. Surv.* **2003**, *35*, 399–458, doi:10.1145/954339.954342.
11. Kumari, J.; Rajesh, R.; Pooja, K.M. Facial Expression Recognition: A Survey. *Procedia Computer Science* **2015**, *58*, 486–491, doi:10.1016/j.procs.2015.08.011.
12. Li, S.; Deng, W. Deep Facial Expression Recognition: A Survey. *IEEE Trans. Affective Comput.* **2022**, *13*, 1195–1215, doi:10.1109/TAFFC.2020.2981446.
13. Baltrusaitis, T.; Zadeh, A.; Lim, Y.C.; Morency, L.-P. OpenFace 2.0: Facial Behavior Analysis Toolkit. In Proceedings of the 2018 13th IEEE International Conference on Automatic Face & Gesture Recognition (FG 2018); IEEE: Xi'an, May 2018; pp. 59–66.
14. Dominguez-Catena, I.; Paternain, D.; Galar, M. Metrics for Dataset Demographic Bias: A Case Study on Facial Expression Recognition. *IEEE Trans. Pattern Anal. Mach. Intell.* **2024**, *46*, 5209–5226, doi:10.1109/TPAMI.2024.3361979.
15. Jack, R.E.; Garrod, O.G.B.; Yu, H.; Caldara, R.; Schyns, P.G. Facial Expressions of Emotion Are Not Culturally Universal. *Proc. Natl. Acad. Sci. U.S.A.* **2012**, *109*, 7241–7244, doi:10.1073/pnas.1200155109.
16. Zloteanu, M.; Krumhuber, E.G.; Richardson, D.C. Detecting Genuine and Deliberate Displays of Surprise in Static and Dynamic Faces. *Front. Psychol.* **2018**, *9*, 1184, doi:10.3389/fpsyg.2018.01184.
17. Oh, Y.-H.; See, J.; Le Ngo, A.C.; Phan, R.C.-W.; Baskaran, V.M. A Survey of Automatic Facial Micro-Expression Analysis: Databases, Methods, and Challenges. *Front. Psychol.* **2018**, *9*, 1128, doi:10.3389/fpsyg.2018.01128.
18. Acquisti, A.; Brandimarte, L.; Loewenstein, G. Secrets and Likes: The Drive for Privacy and the Difficulty of Achieving It in the Digital Age. *J Consum Psychol* **2020**, *30*, 736–758, doi:10.1002/jcpy.1191.
19. Udahemuka, G.; Djouani, K.; Kurien, A.M. Multimodal Emotion Recognition Using Visual, Vocal and Physiological Signals: A Review. *Applied Sciences* **2024**, *14*, 8071, doi:10.3390/app14178071.

20. Roshdy, A.; Karar, A.; Kork, S.A.; Beyrouthy, T.; Nait-ali, A. Advancements in EEG Emotion Recognition: Leveraging Multi-Modal Database Integration. *Applied Sciences* **2024**, *14*, 2487, doi:10.3390/app14062487.
21. Zhao, X.; Liu, Y.; Chen, T.; Wang, S.; Chen, J.; Wang, L.; Liu, G. Differences in Brain Activations between Micro- and Macro-Expressions Based on Electroencephalography. *Front. Neurosci.* **2022**, *16*, 903448, doi:10.3389/fnins.2022.903448.
22. Dufourq, E.; Bassett, B. Evolutionary Facial Expression Recognition. In Proceedings of the Conference of the South African Institute of Computer Scientists and Information Technologists 2020; ACM: Cape Town South Africa, September 14 2020; pp. 227–236.
23. Sun, B.; Cao, S.; Li, D.; He, J.; Yu, L. Dynamic Micro-Expression Recognition Using Knowledge Distillation. *IEEE Trans. Affective Comput.* **2022**, *13*, 1037–1043, doi:10.1109/TAFFC.2020.2986962.
24. Belharbi, S.; Pedersoli, M.; Koerich, A.L.; Bacon, S.; Granger, E. Guided Interpretable Facial Expression Recognition via Spatial Action Unit Cues. **2024**, doi:10.48550/ARXIV.2402.00281.
25. Yang, J.; Wu, Z.; Wu, R. Micro-Expression Recognition Based on Contextual Transformer Networks. *Vis Comput* **2025**, *41*, 1527–1541, doi:10.1007/s00371-024-03443-x.
26. Jack, R.E.; Garrod, O.G.B.; Yu, H.; Caldara, R.; Schyns, P.G. Facial Expressions of Emotion Are Not Culturally Universal. *Proc. Natl. Acad. Sci. U.S.A.* **2012**, *109*, 7241–7244, doi:10.1073/pnas.1200155109.
27. Mehdi, S.A.M. Cross-Cultural Emotion Recognition through Facial Expressions. **2025**, doi:10.36227/techrxiv.174439533.38508136/v1.
28. Katirai, A. Ethical Considerations in Emotion Recognition Technologies: A Review of the Literature. *AI Ethics* **2024**, *4*, 927–948, doi:10.1007/s43681-023-00307-3.
29. Fan, Y.; Lam, J.C.K.; Li, V.O.K. Demographic Effects on Facial Emotion Expression: An Interdisciplinary Investigation of the Facial Action Units of Happiness. *Sci Rep* **2021**, *11*, 5214, doi:10.1038/s41598-021-84632-9.
30. Almeida, D.; Shmarko, K.; Lomas, E. The Ethics of Facial Recognition Technologies, Surveillance, and Accountability in an Age of Artificial Intelligence: A Comparative Analysis of US, EU, and UK Regulatory Frameworks. *AI Ethics* **2022**, *2*, 377–387, doi:10.1007/s43681-021-00077-w.
31. Salagean, G.L.; Leba, M. Face Recognition: A Literature Review.; 2023; pp. 55–60.
32. Adjabi, I.; Ouahabi, A.; Benzaoui, A.; Taleb-Ahmed, A. Past, Present, and Future of Face Recognition: A Review. *Electronics* **2020**, *9*, 1188, doi:10.3390/electronics9081188.
33. Deng, J.; Zhou, Y.; Zafeiriou, S. Marginal Loss for Deep Face Recognition. In Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW); IEEE: Honolulu, HI, USA, July 2017; pp. 2006–2014.
34. Schroff, F.; Kalenichenko, D.; Philbin, J. FaceNet: A Unified Embedding for Face Recognition and Clustering. **2015**, doi:10.48550/ARXIV.1503.03832.
35. Deng, J.; Guo, J.; Yang, J.; Xue, N.; Kotsia, I.; Zafeiriou, S. ArcFace: Additive Angular Margin Loss for Deep Face Recognition. **2018**, doi:10.48550/ARXIV.1801.07698.

36. Shanthi, P.; Nickolas, S. Facial Landmark Detection and Geometric Feature-Based Emotion Recognition. *IJBM* **2022**, *14*, 138, doi:10.1504/IJBM.2022.121799.
37. Hill, A.; Cootes, T.F.; Taylor, C.J. Active Shape Models and the Shape Approximation Problem. *Image and Vision Computing* **1996**, *14*, 601–607, doi:10.1016/0262-8856(96)01097-9.
38. Matthews, I.; Baker, S. Active Appearance Models Revisited. *International Journal of Computer Vision* **2004**, *60*, 135–164, doi:10.1023/B:VISI.0000029666.37597.d3.
39. Shinwari, A.R.; Jalali Balooch, A.; Alariki, A.A.; Abduljalil Abdulhak, S. A Comparative Study of Face Recognition Algorithms under Facial Expression and Illumination. In Proceedings of the 2019 21st International Conference on Advanced Communication Technology (ICACT); IEEE: PyeongChang Kwangwoon_Do, Korea (South), February 2019; pp. 390–394.
40. Choate, J.; Worth, D.; Nykl, S.; Taylor, C.; Borghetti, B.; Schubert Kabban, C. An Analysis of Precision: Occlusion and Perspective Geometry's Role in 6D Pose Estimation. *Neural Comput & Applic* **2024**, *36*, 1261–1281, doi:10.1007/s00521-023-09094-8.
41. Dakshayani, V.; Locharla, G.R.; Pławiak, P.; Datti, V.; Karri, C. Design of a Gabor Filter-Based Image Denoising Hardware Model. *Electronics* **2022**, *11*, 1063, doi:10.3390/electronics11071063.
42. Lyons, M.; Akamatsu, S.; Kamachi, M.; Gyoba, J. Coding Facial Expressions with Gabor Wavelets. In Proceedings of the Proceedings Third IEEE International Conference on Automatic Face and Gesture Recognition; IEEE Comput. Soc: Nara, Japan, 1998; pp. 200–205.
43. Ying-li Tian; Kanade, T.; Cohn, J.F. Evaluation of Gabor-Wavelet-Based Facial Action Unit Recognition in Image Sequences of Increasing Complexity. In Proceedings of the Proceedings of Fifth IEEE International Conference on Automatic Face Gesture Recognition; IEEE: Washington, DC, USA, 2002; pp. 229–234.
44. Zhao, G.; Pietikainen, M. Dynamic Texture Recognition Using Local Binary Patterns with an Application to Facial Expressions. *IEEE Trans. Pattern Anal. Mach. Intell.* **2007**, *29*, 915–928, doi:10.1109/TPAMI.2007.1110.
45. Caifeng Shan; Shaogang Gong; McOwan, P.W. Robust Facial Expression Recognition Using Local Binary Patterns. In Proceedings of the IEEE International Conference on Image Processing 2005; IEEE: Genova, Italy, 2005; p. II–370.
46. Kola, D.G.R.; Samayamantula, S.K. A Novel Approach for Facial Expression Recognition Using Local Binary Pattern with Adaptive Window. *Multimed Tools Appl* **2021**, *80*, 2243–2262, doi:10.1007/s11042-020-09663-2.
47. Patel, C.I.; Labana, D.; Pandya, S.; Modi, K.; Ghayvat, H.; Awais, M. Histogram of Oriented Gradient-Based Fusion of Features for Human Action Recognition in Action Video Sequences. *Sensors* **2020**, *20*, 7299, doi:10.3390/s20247299.
48. Dalal, N.; Triggs, B. Histograms of Oriented Gradients for Human Detection. In Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and

- Pattern Recognition (CVPR'05); IEEE: San Diego, CA, USA, 2005; Vol. 1, pp. 886–893.
49. Carcagnì, P.; Del Coco, M.; Leo, M.; Distantè, C. Facial Expression Recognition and Histograms of Oriented Gradients: A Comprehensive Study. *SpringerPlus* **2015**, *4*, 645, doi:10.1186/s40064-015-1427-3.
 50. Tanjung, J.P.; Muhathir, M. Classification of Facial Expressions Using SVM and HOG. *JITE* **2020**, *3*, 210–215, doi:10.31289/jite.v3i2.3182.
 51. Connie, T.; Al-Shabi, M.; Cheah, W.P.; Goh, M. Facial Expression Recognition Using a Hybrid CNN–SIFT Aggregator. In *Multi-disciplinary Trends in Artificial Intelligence*; Phon-Amnuaisuk, S., Ang, S.-P., Lee, S.-Y., Eds.; Lecture Notes in Computer Science; Springer International Publishing: Cham, 2017; Vol. 10607, pp. 139–149 ISBN 978-3-319-69455-9.
 52. Azeem, A.; Sharif, M.; Shah, J.H.; Raza, M. Hexagonal Scale Invariant Feature Transform (H-SIFT) for Facial Feature Extraction. *Journal of Applied Research and Technology* **2015**, *13*, 402–408, doi:10.1016/j.jart.2015.07.006.
 53. Li, S.; Deng, W. Deep Facial Expression Recognition: A Survey. *IEEE Trans. Affective Comput.* **2022**, *13*, 1195–1215, doi:10.1109/TAFFC.2020.2981446.
 54. Pantie, M.; Rothkrantz, L.J.M. Automatic Analysis of Facial Expressions: The State of the Art. *IEEE Trans. Pattern Anal. Machine Intell.* **2000**, *22*, 1424–1445, doi:10.1109/34.895976.
 55. Belhumeur, P.N.; Hespanha, J.P.; Kriegman, D.J. Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection. *IEEE Trans. Pattern Anal. Machine Intell.* **1997**, *19*, 711–720, doi:10.1109/34.598228.
 56. Juwei Lu; Plataniotis, K.N.; Venetsanopoulos, A.N. Face Recognition Using LDA-Based Algorithms. *IEEE Trans. Neural Netw.* **2003**, *14*, 195–200, doi:10.1109/tnn.2002.806647.
 57. Turk, M.A.; Pentland, A.P. Face Recognition Using Eigenfaces. In Proceedings of the Proceedings. 1991 IEEE Computer Society Conference on Computer Vision and Pattern Recognition; IEEE Comput. Soc. Press: Maui, HI, USA.
 58. Ramadhani, A.L.; Musa, P.; Wibowo, E.P. Human Face Recognition Application Using Pca and Eigenface Approach. In Proceedings of the 2017 Second International Conference on Informatics and Computing (ICIC); IEEE: Jayapura, November 2017; pp. 1–5.
 59. Sariyanidi, E.; Gunes, H.; Cavallaro, A. Automatic Analysis of Facial Affect: A Survey of Registration, Representation, and Recognition. *IEEE Trans. Pattern Anal. Mach. Intell.* **2015**, *37*, 1113–1133, doi:10.1109/TPAMI.2014.2366127.
 60. Cortes, C.; Vapnik, V. Support-Vector Networks. *Mach Learn* **1995**, *20*, 273–297, doi:10.1007/BF00994018.
 61. Michel, P.; El Kaliouby, R. Real Time Facial Expression Recognition in Video Using Support Vector Machines. In Proceedings of the Proceedings of the 5th international conference on Multimodal interfaces; ACM: Vancouver British Columbia Canada, November 5 2003; pp. 258–264.

62. Shan, C.; Gong, S.; McOwan, P.W. Facial Expression Recognition Based on Local Binary Patterns: A Comprehensive Study. *Image and Vision Computing* **2009**, *27*, 803–816, doi:10.1016/j.imavis.2008.08.005.
63. Viola, P.; Jones, M. Rapid Object Detection Using a Boosted Cascade of Simple Features. In Proceedings of the Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. CVPR 2001; IEEE Comput. Soc: Kauai, HI, USA, 2001; Vol. 1, p. I-511-I-518.
64. Yongmian Zhang; Qiang Ji; Zhiwei Zhu; Beifang Yi Dynamic Facial Expression Analysis and Synthesis With MPEG-4 Facial Animation Parameters. *IEEE Trans. Circuits Syst. Video Technol.* **2008**, *18*, 1383–1396, doi:10.1109/TCSVT.2008.928887.
65. Fatchan, M.; Andono, P.N.; Affandy, A.; Fanani, A.Z. Hybrid Deep Autoencoder and AdaBoost for Robust Facial Expression Recognition. *IJCMEM* **2025**, *13*, 141–147, doi:10.18280/ijcmem.130115.
66. Rabiner, L.R. A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition. *Proc. IEEE* **1989**, *77*, 257–286, doi:10.1109/5.18626.
67. Cohen, I.; Sebe, N.; Garg, A.; Chen, L.S.; Huang, T.S. Facial Expression Recognition from Video Sequences: Temporal and Static Modeling. *Computer Vision and Image Understanding* **2003**, *91*, 160–187, doi:10.1016/S1077-3142(03)00081-X.
68. Masur, P.B.S.; Costa, W.; Figueredo, L.S.; Teichrieb, V. Leveraging Previous Facial Action Units Knowledge for Emotion Recognition on Faces. **2023**, doi:10.48550/ARXIV.2311.11980.
69. Tian, Y.-L.; Kanade, T.; Cohn, J.F. Facial Expression Analysis. In *Handbook of Face Recognition*; Springer-Verlag: New York, 2005; pp. 247–275 ISBN 978-0-387-40595-7.
70. Bartlett, M.; Littlewort, G.; Tingfan Wu; Movellan, J. Computer Expression Recognition Toolbox. In Proceedings of the 2008 8th IEEE International Conference on Automatic Face & Gesture Recognition; IEEE: Amsterdam, Netherlands, September 2008; pp. 1–2.
71. Littlewort, G.; Bartlett, M.S.; Fasel, I.; Susskind, J.; Movellan, J. Dynamics of Facial Expression Extracted Automatically from Video. *Image and Vision Computing* **2006**, *24*, 615–625, doi:10.1016/j.imavis.2005.09.011.
72. Whitehill, J.; Littlewort, G.; Fasel, I.; Bartlett, M.; Movellan, J. Toward Practical Smile Detection. *IEEE Trans. Pattern Anal. Mach. Intell.* **2009**, *31*, 2106–2111, doi:10.1109/TPAMI.2009.42.
73. Chu, W.-S.; De La Torre, F.; Cohn, J.F. Selective Transfer Machine for Personalized Facial Expression Analysis. *IEEE Trans. Pattern Anal. Mach. Intell.* **2017**, *39*, 529–545, doi:10.1109/TPAMI.2016.2547397.
74. Noldus Information Technology *FaceReader: Tool for Automatic Analysis of Facial Expressions. Reference Manual Version 6.0.*; The Netherlands: Noldus Information Technology: Wageningen, 2015;
75. Cootes, T.F.; Edwards, G.J.; Taylor, C.J. Active Appearance Models. *IEEE Trans. Pattern Anal. Machine Intell.* **2001**, *23*, 681–685, doi:10.1109/34.927467.

76. Van Kuilenburg, H.; Wiering, M.; Den Uyl, M. A Model Based Method for Automatic Facial Expression Recognition. In *Machine Learning: ECML 2005*; Gama, J., Camacho, R., Brazdil, P.B., Jorge, A.M., Torgo, L., Eds.; Lecture Notes in Computer Science; Springer Berlin Heidelberg: Berlin, Heidelberg, 2005; Vol. 3720, pp. 194–205 ISBN 978-3-540-29243-2.
77. Lewinski, P.; Den Uyl, T.M.; Butler, C. Automated Facial Coding: Validation of Basic Emotions and FACS AUs in FaceReader. *Journal of Neuroscience, Psychology, and Economics* **2014**, *7*, 227–236, doi:10.1037/npe0000028.
78. Skiendziel, T.; Rösch, A.G.; Schultheiss, O.C. Assessing the Convergent Validity between the Automated Emotion Recognition Software Noldus FaceReader 7 and Facial Action Coding System Scoring. *PLoS ONE* **2019**, *14*, e0223905, doi:10.1371/journal.pone.0223905.
79. Parkhi, O.M.; Vedaldi, A.; Zisserman, A. Deep Face Recognition. In Proceedings of the Proceedings of the British Machine Vision Conference 2015; British Machine Vision Association: Swansea, 2015; p. 41.1-41.12.
80. Ding, H.; Zhou, S.K.; Chellappa, R. FaceNet2ExpNet: Regularizing a Deep Face Recognition Net for Expression Recognition. In Proceedings of the 2017 12th IEEE International Conference on Automatic Face & Gesture Recognition (FG 2017); IEEE: Washington, DC, DC, USA, May 2017; pp. 118–126.
81. Krizhevsky, A.; Sutskever, I.; Hinton, G.E. ImageNet Classification with Deep Convolutional Neural Networks. *Commun. ACM* **2017**, *60*, 84–90, doi:10.1145/3065386.
82. Ng, H.-W.; Nguyen, V.D.; Vonikakis, V.; Winkler, S. Deep Learning for Emotion Recognition on Small Datasets Using Transfer Learning. In Proceedings of the Proceedings of the 2015 ACM on International Conference on Multimodal Interaction; ACM: Seattle Washington USA, November 9 2015; pp. 443–449.
83. Zhang, Z.; Luo, P.; Loy, C.C.; Tang, X. From Facial Expression Recognition to Interpersonal Relation Prediction. **2016**, doi:10.48550/ARXIV.1609.06426.
84. Sariyanidi, E.; Gunes, H.; Cavallaro, A. Automatic Analysis of Facial Affect: A Survey of Registration, Representation, and Recognition. *IEEE Trans. Pattern Anal. Mach. Intell.* **2015**, *37*, 1113–1133, doi:10.1109/TPAMI.2014.2366127.
85. Sanchez-Ruiz, M.; Flores-Monroy, J.; Nakano-Miyatake, M.; Escamilla-Hernandez, E.; Perez-Meana, H. Face Expression Recognition Using Recurrent Neural Networks. In Proceedings of the 2023 46th International Conference on Telecommunications and Signal Processing (TSP); IEEE: Prague, Czech Republic, July 12 2023; pp. 148–153.
86. Hochreiter, S.; Schmidhuber, J. Long Short-Term Memory. *Neural Computation* **1997**, *9*, 1735–1780, doi:10.1162/neco.1997.9.8.1735.
87. Zhang, K.; Huang, Y.; Du, Y.; Wang, L. Facial Expression Recognition Based on Deep Evolutional Spatial-Temporal Networks. *IEEE Trans. on Image Process.* **2017**, *26*, 4193–4203, doi:10.1109/TIP.2017.2689999.

88. Khor, H.-Q.; See, J.; Phan, R.C.W.; Lin, W. Enriched Long-Term Recurrent Convolutional Network for Facial Micro-Expression Recognition. **2018**, doi:10.48550/ARXIV.1805.08417.
89. Cho, K.; van Merriënboer, B.; Gulcehre, C.; Bahdanau, D.; Bougares, F.; Schwenk, H.; Bengio, Y. Learning Phrase Representations Using RNN Encoder-Decoder for Statistical Machine Translation. **2014**, doi:10.48550/ARXIV.1406.1078.
90. Yap, C.H.; Yap, M.H.; Davison, A.K.; Kendrick, C.; Li, J.; Wang, S.; Cunningham, R. 3D-CNN for Facial Micro- and Macro-Expression Spotting on Long Video Sequences Using Temporal Oriented Reference Frame. **2021**, doi:10.48550/ARXIV.2105.06340.
91. Ji, S.; Xu, W.; Yang, M.; Yu, K. 3D Convolutional Neural Networks for Human Action Recognition. *IEEE Trans. Pattern Anal. Mach. Intell.* **2013**, *35*, 221–231, doi:10.1109/TPAMI.2012.59.
92. Tran, D.; Wang, H.; Torresani, L.; Ray, J.; LeCun, Y.; Paluri, M. A Closer Look at Spatiotemporal Convolutions for Action Recognition. In Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition; IEEE: Salt Lake City, UT, June 2018; pp. 6450–6459.
93. Donahue, J.; Hendricks, L.A.; Rohrbach, M.; Venugopalan, S.; Guadarrama, S.; Saenko, K.; Darrell, T. Long-Term Recurrent Convolutional Networks for Visual Recognition and Description. *IEEE Trans. Pattern Anal. Mach. Intell.* **2017**, *39*, 677–691, doi:10.1109/TPAMI.2016.2599174.
94. Simonyan, K.; Zisserman, A. Two-Stream Convolutional Networks for Action Recognition in Videos. **2014**, doi:10.48550/ARXIV.1406.2199.
95. Fortun, D.; Bouthemy, P.; Kervrann, C. Optical Flow Modeling and Computation: A Survey. *Computer Vision and Image Understanding* **2015**, *134*, 1–21, doi:10.1016/j.cviu.2015.02.008.
96. Liu, Y.-J.; Zhang, J.-K.; Yan, W.-J.; Wang, S.-J.; Zhao, G.; Fu, X. A Main Directional Mean Optical Flow Feature for Spontaneous Micro-Expression Recognition. *IEEE Trans. Affective Comput.* **2016**, *7*, 299–310, doi:10.1109/TAFFC.2015.2485205.
97. Wang, S.-J.; Yan, W.-J.; Li, X.; Zhao, G.; Zhou, C.-G.; Fu, X.; Yang, M.; Tao, J. Micro-Expression Recognition Using Color Spaces. *IEEE Trans. on Image Process.* **2015**, *24*, 6034–6047, doi:10.1109/TIP.2015.2496314.
98. Pfister, T.; Xiaobai Li; Zhao, G.; Pietikainen, M. Recognising Spontaneous Facial Micro-Expressions. In Proceedings of the 2011 International Conference on Computer Vision; IEEE: Barcelona, Spain, November 2011; pp. 1449–1456.
99. Oh, T.-H.; Jaroensri, R.; Kim, C.; Elgharib, M.; Durand, F.; Freeman, W.T.; Matusik, W. Learning-Based Video Motion Magnification. **2018**, doi:10.48550/ARXIV.1804.02684.
100. Wu, H.-Y.; Rubinstein, M.; Shih, E.; Guttag, J.; Durand, F.; Freeman, W. Eulerian Video Magnification for Revealing Subtle Changes in the World. *ACM Trans. Graph.* **2012**, *31*, 1–8, doi:10.1145/2185520.2185561.
101. Park, S.Y.; Lee, S.H.; Ro, Y.M. Subtle Facial Expression Recognition Using Adaptive Magnification of Discriminative Facial Motion. In Proceedings of the Proceedings of

- the 23rd ACM international conference on Multimedia; ACM: Brisbane Australia, October 13 2015; pp. 911–914.
102. Le Ngo, A.C.; Johnston, A.; Phan, R.C.-W.; See, J. Micro-Expression Motion Magnification: Global Lagrangian vs. Local Eulerian Approaches. In Proceedings of the 2018 13th IEEE International Conference on Automatic Face & Gesture Recognition (FG 2018); IEEE: Xi'an, May 2018; pp. 650–656.
 103. Reddy, S.P.T.; Karri, S.T.; Dubey, S.R.; Mukherjee, S. Spontaneous Facial Micro-Expression Recognition Using 3D Spatiotemporal Convolutional Neural Networks. **2019**, doi:10.48550/ARXIV.1904.01390.
 104. Liong, S.-T.; Gan, Y.S.; Yau, W.-C.; Huang, Y.-C.; Ken, T.L. OFF-ApexNet on Micro-Expression Recognition System. **2018**, doi:10.48550/ARXIV.1805.08699.
 105. Peng, M.; Wu, Z.; Zhang, Z.; Chen, T. From Macro to Micro Expression Recognition: Deep Learning on Small Datasets Using Transfer Learning. In Proceedings of the 2018 13th IEEE International Conference on Automatic Face & Gesture Recognition (FG 2018); IEEE: Xi'an, May 2018; pp. 657–661.
 106. Kollias, D.; Zafeiriou, S. Expression, Affect, Action Unit Recognition: Aff-Wild2, Multi-Task Learning and ArcFace. **2019**, doi:10.48550/ARXIV.1910.04855.
 107. Sajjad, M.; Ullah, F.U.M.; Ullah, M.; Christodoulou, G.; Alaya Cheikh, F.; Hijji, M.; Muhammad, K.; Rodrigues, J.J.P.C. A Comprehensive Survey on Deep Facial Expression Recognition: Challenges, Applications, and Future Guidelines. *Alexandria Engineering Journal* **2023**, *68*, 817–840, doi:10.1016/j.aej.2023.01.017.
 108. Jain, N.; Kumar, S.; Kumar, A.; Shamsolmoali, P.; Zareapoor, M. Hybrid Deep Neural Networks for Face Emotion Recognition. *Pattern Recognition Letters* **2018**, *115*, 101–106, doi:10.1016/j.patrec.2018.04.010.
 109. Wang, C.; Peng, M.; Bi, T.; Chen, T. Micro-Attention for Micro-Expression Recognition. *Neurocomputing* **2020**, *410*, 354–362, doi:10.1016/j.neucom.2020.06.005.
 110. Ruder, S. An Overview of Multi-Task Learning in Deep Neural Networks. **2017**, doi:10.48550/ARXIV.1706.05098.
 111. Zhao, K.; Chu, W.-S.; Zhang, H. Deep Region and Multi-Label Learning for Facial Action Unit Detection. In Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR); IEEE: Las Vegas, NV, USA, June 2016; pp. 3391–3399.
 112. Garcez, A. d'Avila; Lamb, L.C. Neurosymbolic AI: The 3rd Wave. **2020**, doi:10.48550/ARXIV.2012.05876.
 113. Zhao, Z.; Patras, I. Prompting Visual-Language Models for Dynamic Facial Expression Recognition. **2024**, doi:10.48550/arXiv.2308.13382.
 114. Nguyen, X.-B.; Duong, C.N.; Li, X.; Gauch, S.; Seo, H.-S.; Luu, K. Micron-BERT: BERT-Based Facial Micro-Expression Recognition. **2023**, doi:10.48550/arXiv.2304.03195.
 115. Lian, Z.; Sun, L.; Sun, H.; Chen, K.; Wen, Z.; Gu, H.; Liu, B.; Tao, J. GPT-4V with Emotion: A Zero-Shot Benchmark for Generalized Emotion Recognition. **2024**, doi:10.48550/arXiv.2312.04293.

116. Zhang, L. MicroEmo: Time-Sensitive Multimodal Emotion Recognition with Micro-Expression Dynamics in Video Dialogues. **2024**, doi:10.48550/arXiv.2407.16552.
117. Zhao, Z.; Cao, Y.; Gong, S.; Patras, I. Enhancing Zero-Shot Facial Expression Recognition by LLM Knowledge Transfer. **2024**, doi:10.48550/arXiv.2405.19100.
118. Lan, X.; Xue, J.; Qi, J.; Jiang, D.; Lu, K.; Chua, T.-S. ExpLLM: Towards Chain of Thought for Facial Expression Recognition. **2024**, doi:10.48550/arXiv.2409.02828.
119. Li, S.; Deng, W. Deep Facial Expression Recognition: A Survey. **2018**, doi:10.1109/TAFFC.2020.2981446.
120. Lucey, P.; Cohn, J.F.; Kanade, T.; Saragih, J.; Ambadar, Z.; Matthews, I. The Extended Cohn-Kanade Dataset (CK+): A Complete Dataset for Action Unit and Emotion-Specified Expression. In Proceedings of the 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition - Workshops; IEEE: San Francisco, CA, USA, June 2010; pp. 94–101.
121. Goodfellow, I.J.; Shlens, J.; Szegedy, C. Explaining and Harnessing Adversarial Examples. **2015**, doi:10.48550/arXiv.1412.6572.
122. Mittelstadt, B.D.; Allo, P.; Taddeo, M.; Wachter, S.; Floridi, L. The Ethics of Algorithms: Mapping the Debate. *Big Data & Society* **2016**, 3, 2053951716679679, doi:10.1177/2053951716679679.
123. Li, X.; Hong, X.; Moilanen, A.; Huang, X.; Pfister, T.; Zhao, G.; Pietikainen, M. Towards Reading Hidden Emotions: A Comparative Study of Spontaneous Micro-Expression Spotting and Recognition Methods. *IEEE Trans. Affective Comput.* **2018**, 9, 563–577, doi:10.1109/TAFFC.2017.2667642.
124. Jain, A.; Bhakta, D. Micro-Expressions: A Survey. *Multimed Tools Appl* **2023**, 83, 53165–53200, doi:10.1007/s11042-023-17313-6.
125. Dwivedi, R.; Kumar, D. Challenges of Facial Micro-Expression Detection and Recognition: A Survey. In *Neural Information Processing*; Tanveer, M., Agarwal, S., Ozawa, S., Ekbal, A., Jatowt, A., Eds.; Communications in Computer and Information Science; Springer Nature Singapore: Singapore, 2023; Vol. 1794, pp. 483–492 ISBN 978-981-99-1647-4.
126. Zhang, K.; Huang, Y.; Du, Y.; Wang, L. Facial Expression Recognition Based on Deep Evolutional Spatial-Temporal Networks. *IEEE Trans. on Image Process.* **2017**, 26, 4193–4203, doi:10.1109/TIP.2017.2689999.
127. Xie, H.-X.; Lo, L.; Shuai, H.-H.; Cheng, W.-H. An Overview of Facial Micro-Expression Analysis: Data, Methodology and Challenge. **2020**, doi:10.48550/ARXIV.2012.11307.
128. Yap, M.H.; See, J.; Hong, X.; Wang, S.-J. Facial Micro-Expressions Grand Challenge 2018 Summary. In Proceedings of the 2018 13th IEEE International Conference on Automatic Face & Gesture Recognition (FG 2018); IEEE: Xi'an, May 2018; pp. 675–678.
129. Fang, Y.; Diallo, A.; Shi, Y.; Jumelle, F.; Shi, B. End-to-End Facial Expression Detection in Long Videos. **2025**, doi:10.48550/arXiv.2504.07660.

130. Zhang, L.; Hong, X.; Arandjelovic, O.; Zhao, G. Short and Long Range Relation Based Spatio-Temporal Transformer for Micro-Expression Recognition. *IEEE Trans. Affective Comput.* **2022**, *13*, 1973–1985, doi:10.1109/TAFFC.2022.3213509.
131. Zhang, M.; Fu, Q.; Chen, Y.-H.; Fu, X. Emotional Context Influences Micro-Expression Recognition. *PLoS ONE* **2014**, *9*, e95018, doi:10.1371/journal.pone.0095018.
132. Zhao, Y.; Xu, J. An Improved Micro-Expression Recognition Method Based on Necessary Morphological Patches. *Symmetry* **2019**, *11*, 497, doi:10.3390/sym11040497.
133. Srinivasan, R.; Martinez, A.M. Cross-Cultural and Cultural-Specific Production and Perception of Facial Expressions of Emotion in the Wild. **2018**, doi:10.48550/arXiv.1808.04399.
134. Kaggle. FER2013 Dataset.
135. Sălăgean, G.L.; Leba, M.; Ionica, A.C. Leveraging Symmetry and Addressing Asymmetry Challenges for Improved Convolutional Neural Network-Based Facial Emotion Recognition. *Symmetry* **2025**, *17*, 397, doi:10.3390/sym17030397.
136. Yan, W.-J.; Li, X.; Wang, S.-J.; Zhao, G.; Liu, Y.-J.; Chen, Y.-H.; Fu, X. CASME II: An Improved Spontaneous Micro-Expression Database and the Baseline Evaluation. *PLoS ONE* **2014**, *9*, e86041, doi:10.1371/journal.pone.0086041.
137. Davison, A.K.; Lansley, C.; Costen, N.; Tan, K.; Yap, M.H. SAMM: A Spontaneous Micro-Facial Movement Dataset. *IEEE Trans. Affective Comput.* **2018**, *9*, 116–129, doi:10.1109/TAFFC.2016.2573832.
138. van Rossum, G., & de Boer, J. Interactively Testing Remote Servers Using the Python Programming Language. *CWI Quarterly* **1991**, *4*, 283–304.
139. Munawar, K.; Naveed, M.S. The Impact of Language Syntax on the Complexity of Programs: A Case Study of Java and Python. *IJIST* **2022**, *4*, 683–695, doi:10.33411/IJIST/2022040310.
140. Dyer, R.; Chauhan, J. An Exploratory Study on the Predominant Programming Paradigms in Python Code. In Proceedings of the Proceedings of the 30th ACM Joint European Software Engineering Conference and Symposium on the Foundations of Software Engineering; ACM: Singapore Singapore, November 7 2022; pp. 684–695.
141. McKinney, W. Data Structures for Statistical Computing in Python.; Austin, Texas, 2010; pp. 56–61.
142. Harris, C.R.; Millman, K.J.; Van Der Walt, S.J.; Gommers, R.; Virtanen, P.; Cournapeau, D.; Wieser, E.; Taylor, J.; Berg, S.; Smith, N.J.; et al. Array Programming with NumPy. *Nature* **2020**, *585*, 357–362, doi:10.1038/s41586-020-2649-2.
143. Abadi, M.; Barham, P.; Chen, J.; Chen, Z.; Davis, A.; Dean, J.; Devin, M.; Ghemawat, S.; Irving, G.; Isard, M.; et al. TensorFlow: A System for Large-Scale Machine Learning. **2016**, doi:10.48550/ARXIV.1605.08695.
144. Pedregosa, F.; Varoquaux, G.; Gramfort, A.; Michel, V.; Thirion, B.; Grisel, O.; Blondel, M.; Müller, A.; Nothman, J.; Louppe, G.; et al. Scikit-Learn: Machine Learning in Python. **2012**, doi:10.48550/ARXIV.1201.0490.
145. Python Software Foundation The Python Standard Library 2025.

146. Ronacher, A. Flask (Version 1.1.2).
147. Django Software Foundation Django Documentation. 2025.
148. Raschka, S.; Patterson, J.; Nolet, C. Machine Learning in Python: Main Developments and Technology Trends in Data Science, Machine Learning, and Artificial Intelligence. **2020**, doi:10.48550/ARXIV.2002.04803.
149. Nelli, F. Image Analysis and Computer Vision with OpenCV. In *Python Data Analytics*; Apress: Berkeley, CA, 2023; pp. 403–422 ISBN 978-1-4842-9531-1.
150. Bhardwaj, N.; Dixit, M. A Review: Facial Expression Detection with Its Techniques and Application. *IJSIP* **2016**, 9, 149–158, doi:10.14257/ijsp.2016.9.6.13.
151. Géron, A. *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow, 2nd Edition*; O'Reilly Media, Inc.: Place of publication not identified, 2019; ISBN 978-1-4920-3263-2.
152. Moroney, L.; Ng, A. *AI and Machine Learning for Coders: A Programmer's Guide to Artificial Intelligence*; First edition, second realease.; O'Reilly: Beijing Boston Farnham, 2021; ISBN 978-1-4920-7819-7.
153. Lugaresi, C.; Tang, J.; Nash, H.; McClanahan, C.; Uboweja, E.; Hays, M.; Zhang, F.; Chang, C.-L.; Yong, M.G.; Lee, J.; et al. MediaPipe: A Framework for Building Perception Pipelines 2019.
154. OpenAI. (2025). About. Available online: <https://openai.com/about/>.
155. Brockman, G.; Cheung, V.; Pettersson, L.; Schneider, J.; Schulman, J.; Tang, J.; Zaremba, W. OpenAI Gym. **2016**, doi:10.48550/arXiv.1606.01540.
156. Bubeck, S.; Chandrasekaran, V.; Eldan, R.; Gehrke, J.; Horvitz, E.; Kamar, E.; Lee, P.; Lee, Y.T.; Li, Y.; Lundberg, S.; et al. Sparks of Artificial General Intelligence: Early Experiments with GPT-4 2023.
157. Radford, A.; Kim, J.W.; Hallacy, C.; Ramesh, A.; Goh, G.; Agarwal, S.; Sastry, G.; Askell, A.; Mishkin, P.; Clark, J.; et al. Learning Transferable Visual Models From Natural Language Supervision. **2021**, doi:10.48550/ARXIV.2103.00020.
158. Lynch, C.J.; Jensen, E.; Munro, M.H.; Zamponi, V.; Martinez, J.; O'Brien, K.; Feldhaus, B.; Smith, K.; Reinhold, A.M.; Gore, R. GPT-4 Generated Narratives of Life Events Using a Structured Narrative Prompt: A Validation Study 2024.
159. Ramesh, A.; Pavlov, M.; Goh, G.; Gray, S.; Voss, C.; Radford, A.; Chen, M.; Sutskever, I. Zero-Shot Text-to-Image Generation. **2021**, doi:10.48550/ARXIV.2102.12092.
160. Lan, X.; Xue, J.; Qi, J.; Jiang, D.; Lu, K.; Chua, T.-S. ExpLLM: Towards Chain of Thought for Facial Expression Recognition 2024.
161. OpenAI. Our Approach to AI Safety.
162. Viola, P.; Jones, M.J. Robust Real-Time Face Detection. *International Journal of Computer Vision* **2004**, 57, 137–154, doi:10.1023/B:VISI.0000013087.49260.fb.
163. Farfade, S.S.; Saberian, M.J.; Li, L.-J. Multi-View Face Detection Using Deep Convolutional Neural Networks. In Proceedings of the Proceedings of the 5th ACM on International Conference on Multimedia Retrieval; ACM: Shanghai China, June 22 2015; pp. 643–650.

164. Tomasi, C.; Manduchi, R. Bilateral Filtering for Gray and Color Images. In Proceedings of the Sixth International Conference on Computer Vision (IEEE Cat. No.98CH36271); Narosa Publishing House: Bombay, India, 1998; pp. 839–846.
165. Lindenbaum, M.; Fischer, M.; Bruckstein, A. On Gabor's Contribution to Image Enhancement. *Pattern Recognition* **1994**, *27*, 1–8, doi:10.1016/0031-3203(94)90013-2.
166. Pizer, S.M.; Amburn, E.P.; Austin, J.D.; Cromartie, R.; Geselowitz, A.; Greer, T.; Ter Haar Romeny, B.; Zimmerman, J.B.; Zuiderveld, K. Adaptive Histogram Equalization and Its Variations. *Computer Vision, Graphics, and Image Processing* **1987**, *39*, 355–368, doi:10.1016/S0734-189X(87)80186-X.
167. Hawkins, D.M. The Problem of Overfitting. *J. Chem. Inf. Comput. Sci.* **2004**, *44*, 1–12, doi:10.1021/ci0342472.
168. Wang, Z.; Wang, P.; Liu, K.; Wang, P.; Fu, Y.; Lu, C.-T.; Aggarwal, C.C.; Pei, J.; Zhou, Y. A Comprehensive Survey on Data Augmentation. **2024**, doi:10.48550/ARXIV.2405.09591.
169. Gupta, S. Facial Emotion Recognition in Real-Time and Static Images. In Proceedings of the 2018 2nd International Conference on Inventive Systems and Control (ICISC); IEEE: Coimbatore, January 2018; pp. 553–560.
170. Ojala, T.; Pietikainen, M.; Maenpaa, T. Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns. *IEEE Trans. Pattern Anal. Machine Intell.* **2002**, *24*, 971–987, doi:10.1109/TPAMI.2002.1017623.
171. Anthwal, S.; Ganotra, D. An Optical Flow Based Approach for Facial Expression Recognition. In Proceedings of the 2019 International Conference on Power Electronics, Control and Automation (ICPECA); IEEE: New Delhi, India, November 2019; pp. 1–5.
172. Principal Component Analysis for Special Types of Data. In *Principal Component Analysis*; Springer Series in Statistics; Springer-Verlag: New York, 2002; pp. 338–372 ISBN 978-0-387-95442-4.
173. Roy Supta, S.; Rifath Sahriar, Md.; Rashed, Md.G.; Das, D.; Yasmin, R. An Effective Facial Expression Recognition System. In Proceedings of the 2020 IEEE International Women in Engineering (WIE) Conference on Electrical and Computer Engineering (WIECON-ECE); IEEE: Bhubaneswar, India, December 26 2020; pp. 66–69.
174. Goodfellow, I.; Bengio, Y.; Courville, A. *Deep Learning*; Adaptive computation and machine learning; The MIT Press: Cambridge, Massachusetts, 2016; ISBN 978-0-262-03561-3.
175. Cortes, C.; Vapnik, V. Support-Vector Networks. *Mach Learn* **1995**, *20*, 273–297, doi:10.1007/BF00994018.
176. Breiman, L. Random Forests. *Machine Learning* **2001**, *45*, 5–32, doi:10.1023/A:1010933404324.
177. Chutia, T.; Baruah, N. A Review on Emotion Detection by Using Deep Learning Techniques. *Artif Intell Rev* **2024**, *57*, 203, doi:10.1007/s10462-024-10831-1.
178. Verma, G.; Verma, H. Hybrid-Deep Learning Model for Emotion Recognition Using Facial Expressions. *Rev Socionetwork Strat* **2020**, *14*, 171–180, doi:10.1007/s12626-020-00061-6.

179. S. Saha A Comprehensive Guide to Convolutional Neural Networks — the ELI5 Way, 2018.
180. Rackauckas, C.; Ma, Y.; Martensen, J.; Warner, C.; Zubov, K.; Supekar, R.; Skinner, D.; Ramadhan, A.; Edelman, A. Universal Differential Equations for Scientific Machine Learning. **2020**, doi:10.48550/ARXIV.2001.04385.
181. Kingma, D.P.; Ba, J. Adam: A Method for Stochastic Optimization. **2014**, doi:10.48550/ARXIV.1412.6980.
182. Sălăgean, G.L.; Leba, M.; Ionica, A.C. Seeing the Unseen: Real-Time Micro-Expression Recognition with Action Units and GPT-Based Reasoning. *Applied Sciences* **2025**, *15*, 6417, doi:10.3390/app15126417.
183. Matsumoto, D.; Hwang, H.S. Evidence for Training the Ability to Read Microexpressions of Emotion. *Motiv Emot* **2011**, *35*, 181–191, doi:10.1007/s11031-011-9212-2.
184. M, H.; M.N, S. A Review on Evaluation Metrics for Data Classification Evaluations. *IJDKP* **2015**, *5*, 01–11, doi:10.5121/ijdkp.2015.5201.
185. Vujovic, Ž.Đ. Classification Model Evaluation Metrics. *IJACSA* **2021**, *12*, doi:10.14569/IJACSA.2021.0120670.
186. Vuong Nguyen, L. Classifications, Evaluation Metrics, Datasets, and Domains in Recommendation Services: A Survey. *HIS* **2024**, *20*, 85–100, doi:10.3233/HIS-240003.
187. Terven, J.; Cordova-Esparza, D.-M.; Romero-González, J.-A.; Ramírez-Pedraza, A.; Chávez-Urbiola, E.A. A Comprehensive Survey of Loss Functions and Metrics in Deep Learning. *Artif Intell Rev* **2025**, *58*, 195, doi:10.1007/s10462-025-11198-7.
188. Kulatilleke, G.K.; Samarakoon, S. Empirical Study of Machine Learning Classifier Evaluation Metrics Behavior in Massively Imbalanced and Noisy Data. **2022**, doi:10.48550/ARXIV.2208.11904.
189. Rajesh Kumar; Syed Ibrar Hussain A Review of the Deep Convolutional Neural Networks for the Analysis of Facial Expressions. *Journal of Innovative Technology* **2024**, *6*, doi:10.29424/JIT.202403_6(1).0004.
190. Pramerdorfer, C.; Kampel, M. Facial Expression Recognition Using Convolutional Neural Networks: State of the Art. **2016**, doi:10.48550/ARXIV.1612.02903.
191. <https://www.kaggle.com/datasets/msambare/fer2013?select=train>.
192. <https://www.kaggle.com/datasets/jonathanoheix/face-expression-recognition-dataset/data>.
193. Mollahosseini, A.; Chan, D.; Mahoor, M.H. Going Deeper in Facial Expression Recognition Using Deep Neural Networks. **2015**, doi:10.48550/ARXIV.1511.04110.
194. Minaee, S.; Minaei, M.; Abdolrashidi, A. Deep-Emotion: Facial Expression Recognition Using Attentional Convolutional Network. *Sensors* **2021**, *21*, 3046, doi:10.3390/s21093046.
195. Ghadekar, P.; Gupta, A.K.; Datta, J.; Singh, G.; Anand, D.S.; Oswal, P.; Sharma, D.; Khare, S. Facial Expression Recognition Based on Deep Learning-Deep Convolutional Neural Network. In Proceedings of the 2022 IEEE 7th International Conference on

- Recent Advances and Innovations in Engineering (ICRAIE); IEEE: MANGALORE, India, December 1 2022; pp. 93–98.
196. Khan, A.R. Facial Emotion Recognition Using Conventional Machine Learning and Deep Learning Methods: Current Achievements, Analysis and Remaining Challenges. *Information* **2022**, *13*, 268, doi:10.3390/info13060268.
 197. Christou, N.; Kanojiya, N. Human Facial Expression Recognition with Convolution Neural Networks. In *Third International Congress on Information and Communication Technology*; Yang, X.-S., Sherratt, S., Dey, N., Joshi, A., Eds.; Advances in Intelligent Systems and Computing; Springer Singapore: Singapore, 2019; Vol. 797, pp. 539–545 ISBN 978-981-13-1164-2.
 198. Punuri, S.B.; Kuanar, S.K.; Kolhar, M.; Mishra, T.K.; Alameen, A.; Mohapatra, H.; Mishra, S.R. Efficient Net-XGBoost: An Implementation for Facial Emotion Recognition Using Transfer Learning. *Mathematics* **2023**, *11*, 776, doi:10.3390/math11030776.
 199. Talluri, K.K.; Fiedler, M.-A.; Al-Hamadi, A. Deep 3D Convolutional Neural Network for Facial Micro-Expression Analysis from Video Images. *Applied Sciences* **2022**, *12*, 11078, doi:10.3390/app122111078.
 200. Li, J.; Wang, T.; Wang, S.-J. Facial Micro-Expression Recognition Based on Deep Local-Holistic Network. *Applied Sciences* **2022**, *12*, 4643, doi:10.3390/app12094643.
 201. Hong, J.; Lee, C.; Jung, H. Late Fusion-Based Video Transformer for Facial Micro-Expression Recognition. *Applied Sciences* **2022**, *12*, 1169, doi:10.3390/app12031169.
 202. Belaiche, R.; Liu, Y.; Migniot, C.; Ginhac, D.; Yang, F. Cost-Effective CNNs for Real-Time Micro-Expression Recognition. *Applied Sciences* **2020**, *10*, 4959, doi:10.3390/app10144959.