

KNO-1201-4704

بهبود تشخیص کارآمد چهره با کمک الگوریتم‌های بهینه‌سازی ترکیبی BRO-GOA و شبکه عصبی کانولوشن عمیق

معصومه زمانی پور^۱ Masomeh zamani61@gmail.comمحمدنی امیدوار^۲ mo.omidvar@iau.ac.ir^{۱،۲}گروه کامپیوتر، واحد فیروزآباد، دانشگاه آزاد اسلامی، فیروزآباد، ایران

چکیده

فناوری تشخیص چهره با چشم‌اندازهای امیدبخش خود، در مواجهه با چالش‌هایی چون تغییر وضعیت، انسداد جزئی، تغییرات بیان، روشنایی و داده‌های جانبی، با محدودیت‌هایی روبرو است. این تحقیق یک الگوریتم بهینه‌سازی ترکیبی از BRO-GOA و شبکه عصبی کانولوشن عمیق را برای افزایش دقت و کارایی تشخیص چهره در محیط‌های مزاحم معرفی می‌کند. هدف اصلی این مقاله ایجاد یک رویکرد یادگیری عمیق مبتنی بر بهینه‌سازی برای تشخیص تصاویر چهره است که قادر به پردازش داده‌های پیچیده و نویزی باشد. الگوریتم Battle Royale Optimization Algorithm (BRO) و سیستم فازی نوع II برای حذف نویز و بهبود پردازش بعدی در این مدل به کار رفته‌اند. نتایج تحلیل مقایسه‌ای نشان می‌دهند که مدل پیشنهادی در تمامی مقادیر داده‌های آموزشی LFW، بالاترین دقت را داشته و با افزایش داده‌ها، دقت آن از ۰٫۹۱۶۵ به ۰٫۹۷۴۳ ارتقا می‌یابد. در مقایسه با سایر مدل‌ها، این روش کاهش قابل توجهی در نرخ خطای اشتباه پذیرش (FAR) از ۰٫۴۸ به ۰٫۱۸ و همچنین نرخ خطای رد اشتباه (FRR) از ۰٫۱۷۵ به ۰٫۰۷۲ نشان می‌دهد. مدل پیشنهادی همچنین در تمامی زوایای روشنایی، به ویژه در زاویه‌های ۰ و ۲۰ درجه با دقت‌های ۰٫۹۲۹۳ و ۰٫۹۴۰۳، بهبود عملکرد چشمگیری داشته است. این نتایج حاکی از پایداری بیشتر و عملکرد بهتر این مدل نسبت به سایر روش‌ها در شرایط متغیر و محیط‌های نویزی هستند. در نهایت، روش پیشنهادی با دقت بالا و عملکرد بهینه، انتخاب مناسبی برای کاربردهای واقعی تشخیص چهره در محیط‌های پیچیده است.

کلمات کلیدی: تشخیص چهره، الگوریتم بهینه‌سازی، شبکه عصبی کانولوشن، Battle Royale Optimization, دقت.

مقدمه

با پیشرفت روزافزون فناوری در حوزه سیستم‌های بیومتریک، تشخیص چهره به یکی از مهم‌ترین ابزارها در بینایی ماشین و بینایی رایانه تبدیل شده است [۱]. سیستم‌های بیومتریک، مانند تشخیص چهره، به دلیل قابلیت اطمینان بالا و پتانسیل عملکرد موفق در شرایط سخت یا در برابر جعل، توجه بسیاری را به خود جلب کرده‌اند. فناوری‌های پیشرفته‌ای مانند شبکه‌های عصبی کانولوشن عمیق (DCNN) همراه با مجموعه داده‌های بزرگ آموزشی، موجب پیشرفت‌های چشمگیر در این زمینه شده‌اند. در حال حاضر، این سیستم‌ها در حوزه‌هایی مانند نظارت تصویری، کنترل دسترسی ساختمان، و خودروهای خودران کاربرد گسترده‌ای دارند [۲]. با وجود این، چالش‌هایی همچون نورپردازی متغیر، انسداد، وضوح پایین تصویر، و ژست‌های متفاوت چهره، دقت تشخیص را تحت تأثیر قرار می‌دهند [۳]. در این میان، یادگیری عمیق نقش کلیدی در پردازش و پیش‌پردازش داده‌ها ایفا می‌کند و می‌تواند از داده‌های دارای برچسب یا بدون برچسب، ویژگی‌های سطح بالا استخراج کند. مدل‌های عمیق به موفقیت‌های چشمگیری در زمینه‌هایی مانند تشخیص تصویر و گفتار، NLP و حتی تحلیل DNA دست یافته‌اند. با این حال، این مدل‌ها نیز محدودیت‌هایی مانند ناتوانی در حذف کامل تغییرات ژستی خارج از صفحه دارند [۴-۵]. از سوی دیگر، استفاده از الگوریتم‌های فراابتکاری ترکیبی مانند BRO-GOA در تشخیص چهره، با ترکیب چندین استراتژی بهینه‌سازی، موجب افزایش دقت و سرعت تشخیص در شرایط نوری و پس‌زمینه مختلف شده و در برنامه‌های نظارتی


و امنیتی، نقش ارزشمندی ایفا می‌کنند. این الگوریتم‌ها از طریق انتخاب ویژگی‌های مؤثر و بهینه‌سازی پارامترها، پردازش‌های پیچیده را ساده‌تر کرده و تشخیص چهره را در زمان واقعی تسهیل می‌نمایند.

کارهای گذشته

در مجموعه مقالات [۶] تا [۱۲]، نقش کلیدی یادگیری عمیق در بهبود سیستم‌های تشخیص چهره، شناسایی هویت، تحلیل احساسات و کاربردهای امنیتی و بهداشتی مورد بررسی قرار گرفته است. مقاله [۶] به بهبود سیستم حضور و غیاب با استفاده از شبکه‌های CNN پرداخته و مقاله [۷] الگوریتم ++MTCNN را برای تشخیص دقیق اجزای چهره معرفی کرده است. مقاله [۸] چالش‌های تشخیص چهره در تصاویر پهنادی را بررسی می‌کند و مقاله [۹] با ترکیب یادگیری عمیق و الگوریتم بهینه‌سازی هیبریدی، روشی مؤثر برای تشخیص آفات ارائه می‌دهد. مقاله [۱۰] نیز با بهره‌گیری از شبکه‌های یادگیری عمیق و الگوریتم گرگ خاکستری به شناسایی هویت از طریق اثر کف دست پرداخته است. مقاله [۱۱] روش بی‌لینیری پولینگ را برای شناسایی دقیق حالات چهره معرفی کرده و مقاله [۱۲] نیز مدلی برای شناسایی ماسک صورت در محیط‌های IoT با یادگیری عمیق پیشنهاد داده است.

روش پیشنهادی

در اینجا، مدل شبکه عصبی پیچشی عمیق مبتنی بر الگوریتم فراابتکاری ترکیبی برای شناسایی چهره پیشنهاد شده است. نمای مدل پیشنهادی در شکل ۱ نشان داده شده است:



شکل ۱. نمای شماتیک روش پیشنهادی تشخیص چهره

در ابتدا، تصویر ورودی تحت یک مرحله حذف نویز قرار می‌گیرد تا نویز از آن حذف شود و برای پردازش‌های بعدی مناسب گردد. حذف نویز با استفاده از [۱۳] انجام می‌شود که به شناسایی پیکسل‌های نویزی در تصویر برای بهبود پردازش کمک می‌کند. پس از مرحله حذف نویز، استخراج ویژگی‌ها با استفاده از مدل شبکه عصبی پیچشی (CNN) و L^3DMM [۱۴] انجام می‌شود. در اینجا، CNN یک شبکه عصبی چند لایه با معماری خاص برای شناسایی ویژگی‌های پیچیده داده‌ها است و ویژگی DMM^3L برای برآزش یک چهره سه‌بعدی از تصویر غیرمحدود به کار می‌رود. ویژگی‌های به‌دست‌آمده برای شناسایی چهره به شبکه عصبی پیچشی عمیق (Deep CNN) داده می‌شوند. آموزش شبکه عصبی عمیق با استفاده از الگوریتم بهینه‌سازی Gannet optimization algorithm انجام می‌شود. همچنین حذف نویز با استفاده از سیستم فازی نوع II و فیلتر Battle royale optimization algorithm انجام می‌گیرد.

```
% بارگذاری تصویر ورودی 1. %
inputImage = imread('path_to_image.jpg');
% II و سیستم فازی نوع T2FCS حذف نویز با استفاده از 2. %
% (را پیاده‌سازی کنید II و سیستم فازی نوع T2FCS توجه داشته باشید که باید) %
denoisedImage = T2FCS(inputImage); % تابع T2FCS
% Battle Royale Optimization Algorithm (BRO) حذف نویز با استفاده از فیلتر 3. %
% (باید انجام شود BRO پیاده‌سازی) %
denoisedImageBRO = BRO(denoisedImage); % اعمال الگوریتم BRO
% L3DMM و CNN استخراج ویژگی‌ها با استفاده از 4. %
% برای استخراج ویژگی‌ها استفاده می‌شود CNN ابتدا شبکه %
cnnLayers = [
    imageInputLayer([224 224 3], 'Name', 'input')
    convolution2dLayer(3, 32, 'Padding', 'same', 'Name', 'conv1')
    batchNormalizationLayer('Name', 'BN1')
    reluLayer('Name', 'relu1')
    convolution2dLayer(3, 64, 'Padding', 'same', 'Name', 'conv2')
    batchNormalizationLayer('Name', 'BN2')
    reluLayer('Name', 'relu2')
    maxPooling2dLayer(2, 'Stride', 2, 'Name', 'maxpool')
    fullyConnectedLayer(256, 'Name', 'fc1')
    reluLayer('Name', 'relu_fc')
    fullyConnectedLayer(128, 'Name', 'fc2')
    softmaxLayer('Name', 'softmax')
    classificationLayer('Name', 'classOutput')
];
% CNN استخراج ویژگی‌های تصویر از شبکه %
features = activations(cnnLayers, denoisedImageBRO, 'fc2'); % fc2 استخراج از لایه %
% برای برازش چهره سه‌بعدی L3DMM استفاده از 5. %
% (را برای مدل‌سازی چهره سه‌بعدی از تصویر استفاده کنید L3DMM) %
l3dmmFeatures = L3DMM(features); % استخراج ویژگی‌های چهره سه‌بعدی %
% GOA با استفاده از الگوریتم (Deep CNN) آموزش شبکه عصبی پیچشی عمیق 6. %
% برای بهینه‌سازی وزن‌های شبکه عصبی Gannet Optimization (GOA) الگوریتم %
optimizedNet = GOA(cnnLayers, l3dmmFeatures); % GOA بهینه‌سازی شبکه با %
% طبقه‌بندی چهره‌ها با استفاده از شبکه عصبی بهینه‌شده 7. %
% تابع طبقه‌بندی شبکه عصبی آموزش‌دیده بر اساس ویژگی‌های استخراج‌شده %
predictedLabel = classify(optimizedNet, denoisedImageBRO);
```

شکل ۲. شبه کد روش پیشنهادی

در این مقاله، فرآیند شناسایی چهره با بهره‌گیری از الگوریتم‌های ترکیبی [BRO-GOA] و شبکه عصبی کانولوشن عمیق [CNN] به صورت مرحله‌به‌مرحله انجام شده است. ابتدا تصویر ورودی بارگذاری می‌شود و نویز آن با استفاده از روش [FCS^۲T] و سیستم فازی نوع دوم حذف می‌گردد. سپس الگوریتم بهینه‌سازی [BRO] برای بهبود بیشتر کیفیت تصویر و حذف نویزهای باقی‌مانده به کار گرفته می‌شود. پس از پاک‌سازی تصویر، ویژگی‌های کلیدی چهره با استفاده از [CNN] و مدل [DMM^۳L] استخراج می‌شوند. مدل [DMM^۳L] کمک می‌کند تا چهره از حالت دوبعدی به حالت سه‌بعدی تبدیل شده و ویژگی‌های دقیق‌تری جهت پردازش آماده شوند. در ادامه، الگوریتم بهینه‌سازی [GOA] برای تنظیم وزن‌های شبکه عصبی مورد استفاده قرار می‌گیرد تا عملکرد تشخیص بهبود یابد. شبکه عصبی آموزش‌دیده سپس برای طبقه‌بندی چهره‌ها و تشخیص هویت افراد به کار می‌رود. عملکرد مدل با آزمایش آن روی مجموعه‌ای از داده‌های

جدید ارزیابی شده و معیار [دقت مدل] از طریق مقایسه خروجی پیش‌بینی شده با برچسب‌های واقعی محاسبه می‌شود. این چارچوب ترکیبی با بهره‌گیری از الگوریتم‌های هوشمند و مدل‌های پیشرفته عصبی، دقت و کارایی فرایند شناسایی چهره را به شکل قابل توجهی افزایش می‌دهد.

حذف نویز با استفاده از سیستم فازی نوع II و فیلتر Battle royale optimization algorithm

حذف نویز یکی از چالش‌های اساسی در پردازش سیگنال است که می‌تواند تأثیر زیادی بر کیفیت داده‌ها و تحلیل‌های بعدی داشته باشد. سیستم‌های فازی نوع II به دلیل توانایی‌شان در مدیریت عدم قطعیت و ابهام، ابزارهای مؤثری برای این کار به شمار می‌آیند. این سیستم‌ها به جای استفاده از مقادیر دقیق، مجموعه‌هایی از اعداد را برای نمایش عدم قطعیت به کار می‌برند. به این ترتیب، می‌توانند با داده‌های نویزی و غیرقابل پیش‌بینی به خوبی کنار بیایند و در نهایت سیگنال‌های تمیزتری را ارائه دهند. فیلترهای مبتنی بر الگوریتم بهینه‌سازی نبرد رویال (Battle Royale Optimization Algorithm) نیز به عنوان یک روش نوین در حذف نویز شناخته می‌شوند. این الگوریتم با الهام از استراتژی‌های رقابتی در طبیعت، به جستجوی بهینه‌ترین راه‌حل‌ها می‌پردازد. در این روش، هر یک از پروتوتیپ‌ها (نمونه‌ها) که نماینده یک راه‌حل هستند، با یکدیگر رقابت می‌کنند و در نهایت بهترین نمونه‌ها به عنوان راه‌حل نهایی انتخاب می‌شوند. چنین روشی می‌تواند به بهینه‌سازی پارامترهای فیلتر و بهبود کارایی سیستم کمک کند. فرمول‌های مربوط به این دو تکنیک می‌توانند شامل توابع عضویت در سیستم‌های فازی و معیارهای بهینه‌سازی در الگوریتم نبرد رویال باشند. تابع عضویت فازی به صورت زیر تعریف می‌شود:

$$\mu(x) = \frac{x-a}{b-a} \quad \text{for } a \leq x \leq b \quad (1)$$

برای بیان قدرت و موقعیت نمونه‌ها در الگوریتم بهینه‌سازی نبرد رویال، از فرمول‌های زیر استفاده می‌شود:


$$P_i = f(x_i) \quad \text{where } i = 1, 2, \dots, n \quad (2)$$

$$x_{i+1} = x_i + r \cdot (x_j - x_i) \quad \text{for } j \text{ being a better solution} \quad (3)$$

فرمول تابع عضویت فازی شامل متغیرهایی است که به مدیریت عدم قطعیت در داده‌ها کمک می‌کنند؛ به طوری که $\mu(x)$ درجه تعلق عنصر x به یک مجموعه فازی را نشان می‌دهد و مقادیر a و b محدوده‌ای را تعیین می‌کنند که در آن تابع تعریف می‌شود. در الگوریتم بهینه‌سازی نبرد رویال، متغیرها شامل P_i به عنوان قدرت نمونه i و تابع هدف $f(x_i)$ هستند که کیفیت نمونه‌ها را ارزیابی می‌کنند. موقعیت‌های جدید با استفاده از موقعیت فعلی ix و موقعیت یک نمونه بهتر jx به روزرسانی می‌شوند و فاکتور تصادفی r به این تغییرات تنوع می‌بخشد. این ترکیب به بهبود کیفیت سیگنال‌ها و حذف نویز کمک می‌کند.

استخراج ویژگی بر اساس ویژگی‌های CNN و ویژگی مدل سه بعدی شکل پذیر فعال شده (L3DMM)

پس از حذف نویز از تصویر، مرحله استخراج ویژگی با هدف شناسایی دقیق چهره آغاز می‌شود. در این مرحله، ترکیبی از ویژگی‌های شبکه عصبی کانولوشنی عمیق (CNN) و مدل سه بعدی چهره (DMM^{۳L}) مورد استفاده قرار می‌گیرد. تصویر پاک‌سازی شده به شبکه VGG ۱۹ داده می‌شود تا ویژگی‌هایی با ابعاد $[256 \times 1]$ از طریق لایه‌های کانولوشن، pooling و fully connected استخراج گردد. هم‌زمان، با استفاده از روش DMM^{۳L} که مبتنی بر تحلیل اجزای اصلی است، مدل سه بعدی چهره از تصویر دوبعدی بازسازی می‌شود تا شرایط نوری و ساختار هندسی چهره به صورت دقیق در نظر گرفته شود. ترکیب این دو نوع ویژگی موجب بهبود همگرایی، افزایش دقت شناسایی و تسهیل در تطابق مدل چهره می‌گردد.



شکل ۳. ساختار شبکه عصبی کانولوشن عمیق برای ساخت نقشه پیش بینی.

فرض کنید ورودی شبکه عصبی کانولوشن عمیق G است، و بنابراین، خروجی از لایه کانولوشن توسط فرمول زیر محاسبه می شود.

$$(M_c^b)_{i,j} = (B_c^b)_{i,j} + \sum_{d=1}^{d-1} \sum_{k=-w_1^d}^{w_1^d} \sum_{n=-w_2^d}^{w_2^d} (g_{c,d}^b)_{k,n} * (J)_{i+k,j+n} \quad (4)$$

عملیات کانولوشن با نماد $*$ نشان داده می شود و نقشه های ویژگی ثابت به صورت $(Bbc)_i$ ، z نمایش داده می شوند. خروجی از $(b-1)$ لایه به عنوان ورودی لایه کانولوشن h عمل می کند. وزن لایه کانولوشن به صورت $d, \theta bc$ نشان داده می شود و سوگیری لایه کانولوشن h به صورت Bbc بیان می شود. نقشه های ویژگی با k و n نشان داده می شوند.

نتایج روش پیشنهادی

نتایج روش پیشنهادی در قالب جداول و نمودار در این فصل بیان خواهد شد. پیاده سازی با استفاده از نرم افزار متلب ورژن ۲۰۲۲ با استفاده از چهره های برجسب گذاری شده در مجموعه داده (LFW)[15]، پایگاه داده مجموعه داده چهره سه بعدی (UMB-DB) [16] و پایگاه داده توسعه یافته Yale B [17] انجام می شود. پایگاه داده Extended Yale B شامل ۱۶۱۲۸ تصویر از سوژه های انسانی با ۶۴ وضعیت روشنایی و ۹ حالت است. پایگاه داده UMB-DB متشکل از ۱۴۷۳ جفت تصویر رنگی و عمقی با ۱۴۳ سوژه، با حالات مختلف چهره و اشیاء نیمه بسته مانند کلاه، دست و روسری است که در مجموع شامل ۵۷۸ عکس مسدود شده است. پایگاه داده LFW حاوی چهره های برجسب گذاری شده برای تأیید چهره با تصاویر اصلی و تراز شده است. شکل ۴ تصاویری از افراد به دست آمده با استفاده از پایگاه داده LFW را نشان می دهد.




شکل ۴. نتایج تصویر با استفاده از چهره های برجسب گذاری شده در پایگاه داده (LFW)

در این پایان نامه، روش های مورد استفاده برای مقایسه عبارتند از: [18]، [19]، Whale Optimization Algorithm (WOA) + DCNN و [20].

در ادامه یک ارزیابی مقایسه‌ای از روش پیشنهادی را با استفاده از سه مجموعه داده مجزا، با تمرکز بر معیارهای دقت، نرخ پذیرش نادرست (FAR) و نرخ رد نادرست (FRR) ارائه می‌کنیم.


تحلیل با استفاده از پایگاه داده LFW

مدل پیشنهادی معرفی شده، بر روی مجموعه داده LFW در شرایط گوناگونی از میزان داده‌های آموزشی و سطوح مختلف نویز بررسی شده است. شکل ۵ نشان‌دهنده مقایسه عملکرد این مدل با سایر روش‌های سنتی از نظر دقت، نرخ پذیرش اشتباه (FAR)، و نرخ رد اشتباه (FRR) در درصدی از داده‌های آموزشی است.



شکل ۵. تجزیه و تحلیل بر اساس پایگاه داده LFW بر اساس داده‌های آموزشی.

در تحلیل مقایسه‌ای عملکرد مدل‌ها بر اساس داده‌های آموزشی مجموعه LFW، نتایج حاکی از برتری مدل پیشنهادی در تمامی معیارهای ارزیابی است. این مدل در معیار دقت (Accuracy) از مقدار ۰,۹۱۶۵ در ۴۵ درصد داده‌های آموزشی شروع کرده و با افزایش میزان داده‌ها به دقت ۰,۹۷۴۳ در ۹۵ درصد می‌رسد که در مقایسه با سایر مدل‌ها بالاترین نرخ دقت را نشان می‌دهد. همچنین، بررسی نرخ خطای پذیرش اشتباه (FAR) بیانگر آن است که مدل پیشنهادی در تمامی درصدهای آموزش، پایین‌ترین نرخ خطا را دارد و مقدار آن از ۰,۴۸ به ۰,۱۸ کاهش می‌یابد. این روند نزولی نشان‌دهنده افزایش پایداری و توانایی مدل در تفکیک صحیح نمونه‌هاست. در تحلیل نرخ خطای رد اشتباه (FRR) نیز مدل پیشنهادی با روندی آهسته‌تر در افزایش خطا نسبت به سایر روش‌ها عمل کرده، به‌طوری که از مقدار اولیه ۰,۱۷۵ به ۰,۷۲ در بیشترین داده‌های آموزشی می‌رسد. این نتایج به‌طور کلی بیانگر عملکرد دقیق، پایدار و بهینه مدل پیشنهادی در مقایسه با سایر مدل‌های بررسی شده هستند.




شکل ۶. تجزیه و تحلیل با استفاده از پایگاه داده UMB-DB در مواجهه با انسدادهای مختلف

با بررسی داده‌های ارائه‌شده، روش پیشنهادی عملکرد بهتری نسبت به سایر روش‌ها نشان می‌دهد و به‌ویژه در انسدادهای پیچیده مانند ماسک و کلاه دقت بیشتری دارد. روش پیشنهادی در تمامی موارد دارای روند صعودی است و با افزایش پیچیدگی انسداد، بهبود بیشتری در دقت حاصل می‌کند. این در حالی است که سایر روش‌ها در برخی موارد دارای افت یا ثبات در دقت هستند.

تجزیه و تحلیل با استفاده از پایگاه داده توسعه یافته Yale B

عملکرد مدل پیشنهادی بر روی پایگاه داده Extended Yale B در شرایط تغییرات نور و زاویه قرارگیری ارزیابی شده است. نمودارهای مربوط به شکل ۷ دقت (Accuracy) را برای روش پیشنهادی و روش‌های دیگر را در زوایای نور مختلف نشان می‌دهند.



شکل ۷. تجزیه و تحلیل با استفاده از پایگاه داده Yale B توسعه یافته توسط زاویه روشنایی.

داده‌های ارائه‌شده نشان می‌دهد که روش پیشنهادی در تمامی زاویه‌های روشنایی عملکرد برتری دارد و بالاترین دقت‌ها را ثبت می‌کند. به‌طور خاص، در زاویه‌های ۰ و ۲۰ درجه، دقت این روش به ترتیب به ۰٫۹۲۹۳ و ۰٫۹۴۰۳ می‌رسد که بیشترین مقدار در میان تمامی روش‌ها است. روش پیشنهادی در تمامی زوایا نه‌تنها بالاترین دقت را دارد، بلکه تغییرات آن نیز نسبت به زاویه‌های مختلف روشنایی کمتر است، که نشان‌دهنده پایداری بیشتر این روش است. در مقابل، روش‌های دیگر تحت تأثیر تغییرات زاویه‌ای ناپایدار هستند و کاهش چشمگیری در دقت خود نشان می‌دهند. مقایسه‌ای از عملکرد مدل پیشنهادی با مدل‌های دیگر در جدول ۱ نشان داده شده است.

جدول ۱. مقایسه‌ای از عملکرد مدل پیشنهادی با مدل های دیگر

پایگاه داده	معیارها		(WOA) + DCNN	[18]	[19]	[20]	روش پیشنهادی
مجموعه داده LFW	Accuracy	داده های	0.8332	0.8486	0.8494	0.8934	0.9231
	FAR	آموزش	0.4303	0.4222	0.4324	0.239	0.200
	FRR		0.739	0.483	0.403	0.4943	0.302
	Accuracy	وارianس	0.7804	0.7896	0.7637	0.8683	0.8812
	FAR	نویز	0.3667	0.4244	0.4208	0.2908	0.2205
	FRR		0.4836	0.4622	0.7403	0.4449	0.4056

روش پیشنهادی در معیار دقت داده‌های آموزشی با دستیابی به مقدار ۰,۹۲۳۱، عملکرد بهتری نسبت به سایر روش‌ها از خود نشان داده است، به‌طوری که نسبت به نزدیک‌ترین روش مقایسه‌ای [20]، بهبود ۳,۳۳ درصدی را ثبت کرده و در مقایسه با سایر روش‌ها نیز ارتقاء قابل‌توجهی را به نمایش می‌گذارد. همچنین، نرخ مثبت کاذب (FAR) برای این روش ۰,۲۰۰۰ گزارش شده است که کمترین میزان در میان مدل‌های مورد مقایسه است و بیانگر قدرت بالای مدل در کاهش تشخیص‌های نادرست مثبت می‌باشد. از سوی دیگر، نرخ منفی کاذب (FRR) نیز با مقدار ۰,۳۰۲۰ نسبت به مدل‌های [19] و [20] که به ترتیب مقادیر ۰,۴۰۳۰ و ۰,۴۹۴۳ را دارا هستند، بهبود قابل‌توجهی را نشان می‌دهد. در مواجهه با شرایط نویزی، روش پیشنهادی همچنان عملکرد برتری دارد؛ دقت آن برابر با ۰,۸۸۱۲ است که از مقدار دقت ۰,۸۶۸۳ روش [20] فراتر رفته و نسبت به سایر روش‌ها نیز بهتر است. در این وضعیت، نرخ FAR با مقدار ۰,۲۲۰۵ پایین‌ترین میزان را حفظ کرده که بیانگر پایداری الگوریتم در شرایط غیرایده‌آل است. نرخ FRR نیز در شرایط نویزی به ۰,۴۰۵۶ کاهش یافته که در مقایسه با مقدار ۰,۷۴۰۳ روش [19]، کاهش قابل‌ملاحظه‌ای دارد. این نتایج تأکید می‌کنند که روش پیشنهادی با ارائه تعادلی مناسب میان دقت بالا و نرخ خطاهای پایین، نه تنها در محیط‌های آموزشی استاندارد بلکه در شرایط نویزی نیز عملکردی قابل‌اعتماد و برتر ارائه می‌دهد و گزینه‌ای مناسب برای کاربردهای واقعی و پیچیده تلقی می‌شود.

نتیجه‌گیری

فناوری تشخیص چهره با وجود پتانسیل‌های فراوان، با چالش‌هایی مانند تغییر وضعیت، انسداد، بیان چهره، شرایط نوری و نویز مواجه است؛ در این راستا، این مقاله روشی نوین شامل ترکیب الگوریتم بهینه‌سازی [BRO-GOA] و شبکه عصبی کانولوشن عمیق همراه با سیستم فازی نوع II و الگوریتم [Battle Royale Optimization Algorithm] را برای بهبود عملکرد تشخیص چهره در شرایط نویزی ارائه می‌دهد. نتایج حاصل از داده‌های آموزشی [LFW] نشان می‌دهد که مدل پیشنهادی از دقت اولیه ۰,۹۱۶۵ در ۴۵٪ داده‌ها تا ۰,۹۷۴۳ در ۹۵٪ داده‌ها افزایش می‌یابد و در تمامی مراحل، عملکرد بهتری نسبت به سایر روش‌ها دارد. همچنین، نرخ خطای اشتباه پذیرش (FAR) این مدل از ۰,۴۸ به ۰,۱۸ کاهش می‌یابد و نرخ خطای رد اشتباه (FRR) نیز با افزایش آرام‌تری از ۰,۱۷۵ به ۰,۷۲ می‌رسد. این مدل با دقت بالای ۹۰٪ در اکثر شرایط، به‌ویژه در زوایای روشنایی ۰ و ۲۰ درجه با دقت‌های ۰,۹۲۹۳ و ۰,۹۴۰۳، پایداری و برتری خود را اثبات کرده و به عنوان یک راه‌حل مؤثر و قابل‌اتکا در محیط‌های واقعی و چالش‌برانگیز مطرح می‌شود.

مراجع

- [1] Yan, C.; Xie, H.; Chen, J.; Zha, Z.; Hao, X.; Zhang, Y.; Dai, Q. A fast Uyghur text detector for complex background images. *IEEE Trans Multimed.* 2018, 20, 3389–3398. [[Google Scholar](#)] [[CrossRef](#)]
- [2] Soni, N.; Sharma, E.K.; Singh, N.; Kapoor, A. Assistance System (AS) for Vehicles on Indian Roads: A Case Study. In *International Conference on Human Systems Engineering and Design: Future Trends and Applications*; Springer: Cham, Switzerland, 2018; pp. 512–517. [[Google Scholar](#)]
- [3] Chen, Z.; Huang, W.; Lv, Z. Towards a face recognition method based on uncorrelated discriminant sparse preserving projection. *Multimed. Tools Appl.* 2017, 76, 17669–17683. [[Google Scholar](#)] [[CrossRef](#)]

- [۴] Prasad, P.S.; Pathak, R.; Gunjan, V.K.; Rao, H.R. Deep learning based representation for face recognition. In ICCCE; Springer: Singapore, 2019; pp. 419–424. [Google Scholar]
- [۵] Gulli, A.; Kapoor, A.; Pal, S. Deep Learning with TensorFlow 2 and Keras: Regression, ConvNets, GANs, RNNs, NLP, and More with TensorFlow 2 and the Keras API; Packt Publishing Ltd.: Birmingham, UK, 2019.
- [۶] Ali, M., Diwan, A., & Kumar, D. (2024). Attendance System Optimization through Deep Learning Face Recognition. International Journal of Computing and Digital Systems, 15(1), 1527-1540.
- [۷] Khan, S. S., Sengupta, D., Ghosh, A., & Chaudhuri, A. (2024). MTCNN++: A CNN-based face detection algorithm inspired by MTCNN. The Visual Computer, 40(2), 899-917.
- [۸] Rostami, M., Farajollahi, A., & Parvin, H. (2024). Deep learning-based face detection and recognition on drones. Journal of Ambient Intelligence and Humanized Computing, 15(1), 373-387.
- [۹] Thakare, P., & V, R. S. (2024). Advanced pest detection strategy using hybrid optimization tuned deep convolutional neural network. Journal of Engineering, Design and Technology, 22(3), 645-678.
- [۱۰] Alshakree, F., Akbas, A., & Rahebi, J. (2024). Human identification using palm print images based on deep learning methods and gray wolf optimization algorithm. Signal, Image and Video Processing, 18(1), 961-973.
- [۱۱] Hossain, S., Umer, S., Rout, R. K., & Tanveer, M. (2023). Fine-grained image analysis for facial expression recognition using deep convolutional neural networks with bilinear pooling. Applied Soft Computing, 134, 109997.
- [۱۲] Naseri, R. A. S., Kurnaz, A., & Farhan, H. M. (2023). Optimized face detector-based intelligent face mask detection model in IoT using deep learning approach. Applied Soft Computing, 134, 109933.
- [۱۳] Kumar, S.V.; Nagaraju, C. T2FCS filter: Type 2 fuzzy and cuckoo search-based filter design for image restoration. J. Vis. Commun. Image Represent. 2019, 58, 619–641. [Google Scholar] [CrossRef]
- [۱۴] Peng, B.; Wang, W.; Dong, J.; Tan, T. Automatic detection of 3d lighting inconsistencies via a facial landmark based morphable model. In Proceedings of the IEEE International Conference on Image Processing (ICIP), Phoenix, AZ, USA, 25–28 September 2016; pp. 3932–3936. [Google Scholar]
- [۱۵] Labeled Faces in the Wild Home Database. Available online: <http://vis-www.cs.umass.edu/lfw/download> (accessed on 25 July 2020).
- [۱۶] The University of Milano Bicocca 3D Face Database. Available online: <http://www.ivl.disco.unimib.it/minisites/umbdb/request.html> (accessed on 23 July 2020).
- [۱۷] Extended Yale B Database. Available online: <http://vision.ucsd.edu/~leekc/ExtYaleDatabase/ExtYaleB.html> (accessed on 29 July 2020).
- [۱۸] He, M.; Zhang, J.; Shan, S.; Kan, M.; Chen, X. Deformable face net for pose invariant face recognition. Pattern Recognit. 2020, 100, 107113. [Google Scholar] [CrossRef]
- [۱۹] Yang, W.; Zhang, X.; Li, J. A local multiple patterns feature descriptor for face recognition. Neurocomputing 2020, 373, 109–122. [Google Scholar] [CrossRef]
- [۲۰] Soni, N., Sharma, E. K., & Kapoor, A. (2021). Novel BSSO-based deep convolutional neural network for face recognition with multiple disturbing environments. Electronics, 10(5), 626.