

دریافت مقاله: ۱۳۹۵/۰۴/۲۰

پذیرش مقاله: ۱۳۹۶/۰۱/۲۷

## انتخاب ناحیه‌های کاندیدا در سیستم‌های تشخیص و شناسایی اشیاء

علی قنبری سرخی<sup>۱\*</sup>، حمید حسن‌پور<sup>۲</sup>، منصور فاتح<sup>۳</sup>

<sup>۱\*</sup> دانشجوی دکتری، دانشکده مهندسی کامپیوتر، دانشگاه صنعتی شاهرود، شاهرود، ایران

ali.ghanbari289@gmail.com

<sup>۲</sup> استاد، دانشکده مهندسی کامپیوتر، دانشگاه صنعتی شاهرود، شاهرود، ایران

h.hassanpour@shahroodut.ac.ir

<sup>۳</sup> استادیار، دانشکده مهندسی کامپیوتر، دانشگاه صنعتی شاهرود، شاهرود، ایران

mansoor\_fateh@yahoo.com

### چکیده

در تحقیقات انجام شده در سال‌های اخیر، به دست آوردن ناحیه‌های کاندیدا به عنوان یک مرحله اساسی و مهم در سیستم‌های تشخیص و شناسایی اشیاء موجود در تصویر معرفی شده است. به دست آوردن این ناحیه‌ها مانند یک تنگنا بوده و بیشترین بار محاسباتی را در این نوع از سیستم‌ها دارد. در این خصوص، انتخاب روش مناسب و سریع می‌تواند در بهبود عملکرد سیستم‌های تشخیص بسیار حائز اهمیت باشد. در این مقاله، به مرور کارهای انجام شده در این زمینه پرداخته شده و چندین روش مشهور و محبوب مورد استفاده در سیستم‌های شناسایی قدرتمند معرفی شده است. همچنین به مقایسه و ارزیابی روش‌های مطرح بر روی مجموعه داده‌های استاندارد PASCAL VOC، ImageNet، و COCO پرداخته شده است. در بین روش‌های مورد ارزیابی، روش ناحیه کاندیدا گروه‌بندی ترکیبی بر پایه چندین مقیاس (MCG) با الگوریتم شناسایی شبکه عصبی کانولوشن بر پایه ناحیه (R-CNN)، بهترین نتایج را داشته است. این روش عملکردی در حدود ۵۷ درصد، ۵۴ درصد و ۴۱ درصد بر روی مجموعه داده‌های PASCAL VOC 2007، ImageNet 2013 و COCO 2014 نشان داده است.

واژه‌های کلیدی: ناحیه کاندیدا، R-CNN سریع، ابرپیکسل، شیء بودن، تشخیص و شناسایی اشیاء.

## ۱. مقدمه

نزدیک به زمان بلادرنگ در استفاده از شبکه‌های عمیق در صورتی که زمان محاسبه ناحیه‌های پیشنهادی را در نظر نگیریم، به دست آورده است [۵]. در واقع در این شبکه، زمان مربوط به شناسایی ناچیز است.

روش‌های نواحی کاندیدا به طور معمول بر ویژگی‌های ارزان و سریع تکیه می‌کنند. جستجوی انتخابی [۶] یکی از معروف‌ترین روش‌های پیشنهاد ناحیه است که به صورت حریرصانه، ابرپیکسل‌هایی<sup>۸</sup> را که بر اساس ویژگی‌های سطح پایین (مانند میزان شدت روشنایی و رنگ در فضاها رنگی متفاوت) طراحی شده، ادغام می‌کند. اما این روش در مقایسه با شبکه‌های شناسایی کارآمد مانند R-CNN سریع [۴] کندتر است. روش EdgeBoxes پیشنهاد شده در [۷]، اخیراً یک سازش<sup>۹</sup> بین کیفیت کاندیدا و زمان را فراهم کرده است. با وجود این، مراحل تولید نواحی کاندیدا، بار محاسباتی زیادی (از لحاظ زمان اجرا) در شبکه‌های تشخیص ایجاد می‌کنند. باید دقت کرد که معمولاً CNN مبتنی بر ناحیه بر اساس GPU توسعه یافته شده است، در حالی که روش‌های ناحیه کاندیدا بر روی CPU پیاده‌سازی می‌شوند. در واقع بسیاری از روش‌های کاندیدا قابلیت موازی‌سازی را به خوبی ندارند؛ به همین دلیل چنین مقایسه‌ای بین روش‌های پیشنهاد ناحیه و شناسایی شیء در زمان اجرا نابرابر است. همان‌طور که اشاره شد، بهبود عملکرد سیستم‌های تشخیص و شناسایی اشیاء وابستگی زیادی به روش‌های ناحیه کاندیدا دارند. در این خصوص، در این مقاله به کارهای انجام شده در این زمینه می‌پردازیم و روش‌های موجود را معرفی و مقایسه می‌کنیم. از طرفی بیان شد که R-CNN برای شناسایی اشیاء به عنوان یک سیستم مشهور و محبوب بوده و در بسیاری از کارهای صنعتی و تحقیقاتی، مورد استقبال محققان قرار گرفته است. به همین دلیل در این مقاله، برای شناسایی اشیاء، از این روش به همراه روش‌های نواحی کاندیدا استفاده شده است.

سیستم‌های تشخیص اشیاء که در سال‌های اخیر پیشنهاد شده‌اند، به الگوریتم‌های ناحیه‌های کاندیدا<sup>۱</sup> برای تخمین مکان اشیاء بسیار وابسته‌اند. از مهم‌ترین شبکه‌های تشخیص می‌توان به SPPnet [۱] و R-CNN<sup>۳</sup> سریع [۲] اشاره کرد که در سال‌های اخیر، مورد توجه بسیاری از محققان و کاربرهای صنعتی قرار گرفته است. در این روش‌ها نمی‌توان سراسر تصویر را به دلیل محدودیت‌های زمانی و حالت‌های مختلف از اشیاء جستجو کرد. در این خصوص، ابتدا باید ناحیه‌های کاندیدا وجود شیء استخراج شوند. پیشرفت‌های انجام شده سبب بهبود زمان اجرای شبکه‌های تشخیص شده و همچنین نشان داده شده تعیین نواحی کاندیدا مهم‌ترین تنگنای<sup>۴</sup> محاسباتی این گونه روش‌هاست. نمونه‌ای از ناحیه‌های کاندیدا برای بررسی وجود شیء مورد نظر در شکل (۱) نشان داده شده است. همان‌طور که در شکل نشان داده شده، سیستم تشخیص شیء، انتخاب نهایی خود را از ناحیه‌های کاندیدا انجام می‌دهد.


در مرجع [۲]، یک شبکه پیشنهاد ناحیه کاندیدا<sup>۵</sup> (RPN) معرفی شده است. در این شبکه، ویژگی‌های با کانولوشن‌های مختلف استخراج شده از سراسر تصویر به اشتراک گذاشته می‌شود. در نتیجه، زمان مربوط به پیشنهادهای ناحیه را قابل چشم‌پوشی می‌سازد. RPN به طور همزمان مرزهای اشیاء و امتیاز<sup>۶</sup> شیء بودن<sup>۷</sup> را در هر موقعیت از تصویر پیش‌بینی می‌کند. اگرچه در مرجع [۳] محاسبات بالا در شبکه‌های عصبی کانولوشن بر پایه ناحیه به عنوان یک اصل بیان شده، این هزینه‌ها با اشتراک کاندیداهای به دست آمده از کانولوشن، به شدت در حال کاهش است [۱ و ۴]. در آزمایش‌های انجام شده در سال‌های اخیر، R-CNN سریع [۴]، نرخ

1. Region proposal
2. Spatial pyramid pooling network
3. Region-convolutional neural network
4. bottleneck
5. Region Proposal Network
6. Score
7. Objectness

## 8. Superpixels

ابرپیکسل به نواحی اتمیک به هم پیوسته و دارای مفهوم واحد در تصویر گفته می‌شود.

## 9. tradeoff



شکل (۱): نمونه‌ای از ناحیه کاندیدا: الف. تصویر اصلی، ب. اشیاء موجود در تصویر، ج. ناحیه‌های کاندیدا [۸]

به‌طور مستقیم از کانتورهای لبه<sup>۳</sup> (EC) [۱۱, ۱۲] تقسیم می‌شوند. از مهم‌ترین روش‌های موجود در این حوزه می‌توان به موارد زیر اشاره نمود:

- جستجوی انتخابی<sup>۴</sup> [۶ و ۸]: در این روش از ادغام ابرپیکسل‌ها، برای تولید کاندیداها استفاده می‌شود. این روش پارامترهای یادگیری ندارد و از ویژگی‌ها و تابع‌های شباهت برای ادغام ابرپیکسل‌ها استفاده می‌کند. در سال‌های اخیر این روش، به صورت گسترده به عنوان روش کاندیدا برای بسیاری از آشکارسازهای شیء مورد استفاده قرار گرفته شده است.

در مقاله<sup>۵</sup> [۶] جستجوی انتخابی با ترکیب استراتژی جستجوی جامع<sup>۵</sup> و قطعه‌بندی ارائه شده است. در این روش مانند روش‌های قطعه‌بندی، در نمونه‌گیری از ساختار تصویر استفاده شده است. همچنین از جستجوی جامع برای محدود کردن تمامی موقعیت‌های ممکن از اشیاء استفاده شده است. نتایج به دست آمده در این روش، روی مجموعه کوچکی با وابستگی به داده و مستقل از کلاس، بیشترین دقت در مکان‌یابی حاصل شده است. در واقع، در مجموعه داده‌هایی با کلاس‌های از پیش مشخص نبوده، این روش عملکرد خوبی داشته است. همچنین در این روش، آموزشی برای کلاس‌ها به صورت جداگانه صورت نگرفته است. آزمایش‌های انجام شده دقتی برابر با ۹۹ درصد و متوسط میانگین بهترین

در بخش دوم مقاله به معرفی روش‌های پیشنهاد ناحیه‌های کاندیدا پرداخت می‌شود. در قسمت سوم مقاله اشاره می‌شود که کنترل تعداد نواحی کاندیدا می‌تواند در مقایسه بین روش‌ها، بسیار مهم باشد. در این باره، در این قسمت به تحلیل آن پرداخته شده است. معرفی مجموعه داده استفاده شده و مقایسه بین روش‌های موجود، در قسمت‌های چهارم و پنجم این پژوهش بیان شده است.

## ۲. روش‌های پیشنهاد ناحیه کاندیدا

همان‌طور که در قسمت قبل اشاره شد، استخراج ناحیه‌های کاندیدا تأثیر بسیار زیادی در دقت و سرعت روش‌های تشخیص و شناسایی اشیاء در تصاویر دارند. به‌طور کلی، می‌توان روش‌های پیشنهاد نواحی کاندیدا را به چهار دسته روش‌های مبتنی بر گروه‌بندی، امتیازدهی به پنجره کاندیدا، جایگزین و مرجع تقسیم کرد که در ادامه به تشریح این روش‌ها پرداخته شده است.

### ۱.۲. روش‌های مبتنی بر گروه‌بندی

روش‌های مبتنی بر گروه‌بندی برای استخراج ناحیه‌های کاندیدا در سه گروه براساس چگونگی تولید کاندیدا، دسته‌بندی می‌شوند. به‌طور کلی، روش‌های تولید کاندیدا بر پایه گروه‌بندی به گروه‌بندی ابرپیکسل (SP) [۹]، حل کردن مسائل برش گراف چندگانه<sup>۱</sup> (GC) با seeds<sup>۲</sup> [۱۰] متنوع یا

منظور از Seeds، ابرپیکسل‌های استخراج شده از طریق نمونه‌گیری انرژی‌محور است. در مقاله<sup>۱۰</sup> [۱۰] یک تابع انرژی بر پایه شباهت رنگ بین مرزها و هیستوگرام رنگ ابرپیکسل‌ها معرفی شده است.

3. Edge contours

4. <http://koen.me/research/downloads/SelectiveSearchCodeIJCV.zip>

5. Exhaustive

### 1. Multiple graph cut

منظور از برش در گراف، تقسیم رئوس گراف به دو زیرمجموعه ناتهی جدا از هم S و V/S است.

### 2. Seeds: Superpixels extracted via energy-driven sampling

ویژگی‌ها شامل، رنگ در فضای RGB، شدت روشنایی<sup>۱</sup> (I) در تصاویر، کانال رنگی RG به‌همراه RGB، HSV، نرمال شده، H در HSV و C [۱۳] هستند.

شکل (۳) نمونه‌ای از نتایج به‌دست‌آمده از روش جستجوی انتخابی را نشان می‌دهد. در هر تصویر محدوده قرمز ناحیه کاندیدا و محدوده سبز مربوط به ناحیه هدف است. مقداری که زیر هر عکس ذکر شده، میزان همپوشانی این دو محدوده را نشان می‌دهد.



Bike: 0.863

Person: 0.882

شکل (۳): نمونه‌ای از خروجی الگوریتم [۶]. محدوده قرمز، ناحیه کاندیدا روش جستجوی انتخابی و محدوده سبز، ناحیه هدف است

• پریم تصادفی<sup>۲</sup>: در مرجع [۱۴] از شباهت ویژگی‌ها مانند روش جستجوی انتخابی استفاده شده است. در این روش یک فرایند ادغام جدید به‌صورت تصادفی برای ابرپیکسل‌ها معرفی شده است. در این فرایند ادغام همه احتمالات ممکن آموزش داده شده است. با این روش، سرعت به‌صورت قابل ملاحظه‌ای افزایش پیدا کرده است.

• جستجو محلی و سراسری<sup>۳</sup>: در مرجع [۱۵] یک استراتژی مشابه جستجوی انتخابی، برای ادغام ابرپیکسل‌ها پیشنهاد شده است. ولی از ویژگی‌های مختلف و بیشتری استفاده کرده است. در مرحله بعدی، قطعات<sup>۴</sup> تولید شده به عنوان Seeds به‌کار گرفته شده و برای حل کردن برش

همپوشانی بین نواحی پیشنهادی و نواحی صحیح ۰/۸۷۹ در ۱۰۰۹۷ موقعیت را از خود نشان داده است. در این روش از یک الگوریتم گروه‌بندی سلسله مراتبی استفاده شده است. ناحیه در مقایسه با پیکسل اطلاعات بیشتری دارد؛ به همین دلیل، در این مقاله از ویژگی‌ها بر پایه ناحیه بیشتر استفاده شده است. در واقع مجموعه‌ای از پیکسل‌ها که ویژگی‌های یکسانی دارند استفاده می‌شوند. برای انتخاب مجموعه‌ای از ناحیه‌های هم‌پوشان با اشیاء از روش سریع [۹] و [۱۱] استفاده شده است. الگوریتم کلی در شکل (۲) آورده شده است.

#### Algorithm 1: Hierarchical Grouping Algorithm

**Input:** (colour) image

**Output:** Set of object location hypotheses  $L$

Obtain initial regions  $R = \{r_1, \dots, r_n\}$  using [9]

Initialise similarity set  $S = \emptyset$

**foreach** Neighbouring region pair  $(r_i, r_j)$  **do**

    Calculate similarity  $s(r_i, r_j)$

$S = S \cup s(r_i, r_j)$

**while**  $S \neq \emptyset$  **do**

    Get highest similarity  $s(r_i, r_j) = \max(S)$

    Merge corresponding regions  $r_i = r_i \cup r_j$

    Remove similarities regarding  $r_i: S = S \setminus s(r_i, r_*)$

    Remove similarities regarding  $r_j: S = S \setminus s(r_*, r_j)$

    Calculate similarity set  $S_i$  between  $r_i$  and its neighbours

$S = S \cup S_i$

$R = R \cup r_i$

Extract object location boxes  $L$  from all regions in  $R$

#### شکل (۲): الگوریتم گروه‌بندی سلسله‌مراتبی در جستجوی انتخابی [۶]

همان‌طور که اشاره شد، از روش ارائه‌شده در مرجع [۹] برای تولید ناحیه‌های اولیه استفاده شده است. سپس از یک الگوریتم حریم‌بندی ناحیه‌ها باهم استفاده می‌شود. در این الگوریتم، ابتدا شباهت بین همه ناحیه‌های همسایه محاسبه می‌شود و در گام بعدی، ناحیه‌هایی با بیشترین شباهت، باهم ترکیب می‌شوند. این کار تا زمانی ادامه می‌یابد که همه تصاویر به یک ناحیه واحد تبدیل شوند. در این مقاله اشاره شد که ناحیه‌های تولید شده می‌توانند در صحنه‌ها و شرایط روشنایی متفاوت باشند. در همین راستا الگوریتم گروه‌بندی در فضاهای رنگی متفاوت با ویژگی‌های مستقل و متفاوت اجرا شده است. در این روش از معیار شباهت وابسته به چهار پارامتر رنگ، بافت، اندازه و میزان همپوشانی ناحیه‌ها نسبت به هم، برای گروه‌بندی ناحیه‌ها استفاده شده است. این

1. intensity

2. RandomizedPrim

<https://github.com/smanenfr/rp/archive/master.zip>

3. Rantalankila

<https://github.com/Cloud-CV/object-proposals/tree/master/rantalankilaSegments>

4. segments

توضیح دهد. در این مقاله، برجستگی سطح شیء توسط اطلاعات به دست آمده از ابرپیکسل‌ها با یک معیار اندازه‌گیری جدید محاسبه شده است.

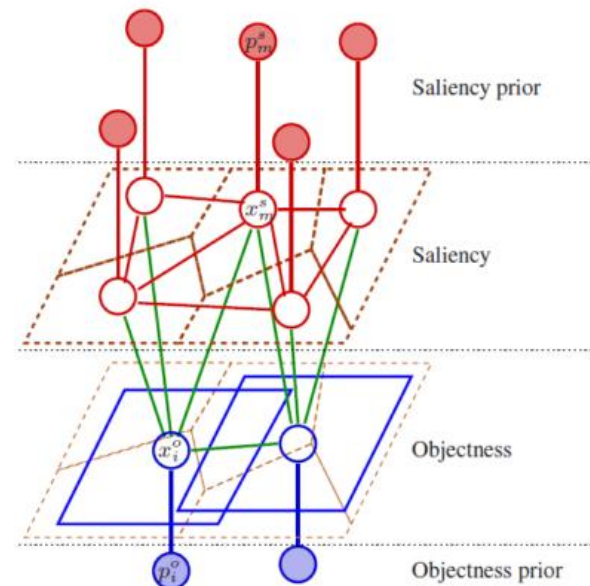
• قطعه‌بندی خودکار با برش‌های کمینه<sup>۴</sup> (CPMC) [۱۷]، [۱۸] از قطعه‌بندی اولیه اجتناب می‌کند و برش‌های گراف را با Seedهای مختلف مستقیماً روی پیکسل محاسبه می‌کند. نتایج قطعه‌بندی با حجم بزرگی از ویژگی‌ها رتبه‌بندی می‌شوند.

در مقاله [۱۷] یک روش جدید برای تولید و رتبه‌بندی اشیاء قابل قبول در تصویر با فرایند پایین به بالا<sup>۵</sup> و نشانه‌های سطح متوسط ارائه شده است. منظور از نشانه‌های سطح متوسط، میزان شباهت بافت، روشنایی، انرژی کانتور بین ناحیه‌ها و درون ناحیه‌هاست. اشیاء به صورت قطعه‌بندی از تصویر استخراج شده است. در این روش، قطعه‌بندی به صورت خودکار و بدون دانش اولیه از خواص کلاس اشیاء بوده است.

برای این منظور، از حل دنباله‌ای از محدوده پارامتری برش کمینه بر روی شبکه منظمی<sup>۶</sup> از تصویر استفاده شده است. در گام بعدی، برای پیش‌بینی میزان قابل قبول بودن قطعه انتخابی، یک مدل پیوسته برای رتبه‌بندی اشیاء آموزش داده می‌شود. این روش برای قطعه‌بندی سطح پایین در مجموعه داده VOC09 عملکرد خوبی را از خود نشان داده است. این روش متوسط بهترین همپوشانی ۰/۷۸ با ۱۵۷ قطعه را دارد. در CMPC برای هر تصویر، مجموعه‌ای از پیکسل‌ها متعلق به پیش‌زمینه فرض می‌شوند. این پیش‌زمینه به عنوان Seeds معرفی می‌شود. سپس برای هر مجموعه، چندین سطوح از پیش‌زمینه استخراج می‌شود. هزینه‌های متفاوتی به همه پیکسل‌های باقی‌مانده اختصاص داده می‌شود. اما بعضی از پیکسل‌های در امتداد مرز تصویر، جز Seed منفی می‌شوند. از الگوریتم‌ها بر پایه گراف به منظور قطعه‌بندی این Seedها استفاده شده است. همچنین میزان شباهت بین پیکسل‌های همسایه به عنوان وزن گراف در

گراف از CPMC<sup>۱</sup> (در قسمت بعد توضیح داده می‌شود) برای تولید کاندیداهای بیشتر استفاده شده است.

• چانگ [۱۶] ترکیبی از برجستگی<sup>۲</sup> و شیء‌بودن با مدل گرافیکی، برای ادغام ابرپیکسل در قطعه‌بندی تصویر/ پس‌زمینه معرفی کرده است. مراحل کلی از مدل گرافی پیشنهادی در شکل (۴) نشان داده شده است.



شکل (۴): مراحل کلی الگوریتم چانگ [۱۶] شامل نمونه‌گیری تصافی جدید و انتصاب مقدار برجستگی به هر پنجره، تخمین شیء‌بودن است.

این روش با نمونه‌گیری تصادفی از پنجره‌های زیاد شروع می‌شود. در گام نخست این روش، تعداد زیادی پنجره، به صورت تصادفی با اندازه‌های متغیر انتخاب می‌شود. به هر پنجره مقدار شیء‌بودن و برای هر پیکسل یا ابرپیکسل مقدار برجستگی اختصاص داده می‌شود. برای ارتباط شیء‌بودن و برجستگی، مقداری به عنوان سطح برجستگی شیء<sup>۳</sup> برای هر پنجره معرفی شده است. این مقدار برای نمایش برجستگی جسم زمینه در هر پنجره استفاده می‌شود. از شیء‌بودن برای تخمین برجستگی استفاده شده است. همچنین از برجستگی برای تخمین شیء‌بودن استفاده شده است. مقدار شیء‌بودن هر پنجره در صورتی بالا خواهد بود که برجستگی سطح شیء به خوبی بتواند بسیاری از مقادیر برجستگی پیکسل‌های را

4. Cpmc: Automatic object segmentation using constrained parametric min-cuts  
[http://www.maths.lth.se/matematiklth/personal/sminchis/code/cpmc/cpmc\\_release1.gz](http://www.maths.lth.se/matematiklth/personal/sminchis/code/cpmc/cpmc_release1.gz)

5. Down-Top

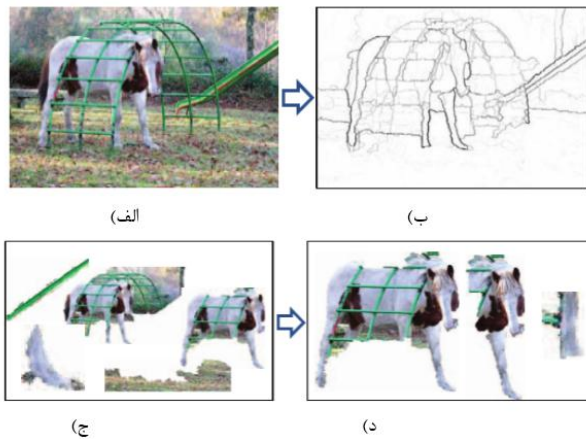
6. cues

7. grid

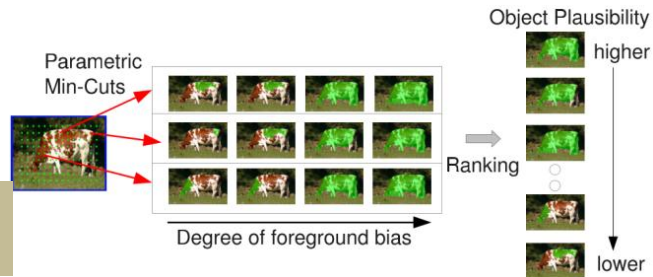
1. Constrained Parametric Min-Cuts

2. Saliency

3. Object-level saliency



شکل (۶): مراحل مختلف از روش [۱۹]، الف. تصویر ورودی، ب. قطعه‌بندی سلسله‌مراتبی، ج. ناحیه‌های کانیدها، د. رتبه‌بندی ناحیه‌ها



شکل (۵): روال پیشنهادشده در [۱۷]

• استحکام داده‌ها<sup>۴</sup> [۲۳] یک روش بهبودیافته از CPMC است که سرعت محاسبه Seedها را با محاسبه مجدد در سراسر مسائل برش گراف چندگانه، به صورت قابل ملاحظه‌ای کاهش می‌دهد. همچنین از روش آشکارسازی سریع لبه استفاده شده است [۱۲ و ۲۴]. این الگوریتم بر روی مجموعه داده PASCAL VOC 2012 مورد ارزیابی قرار گرفته شده است. نتایج آزمایش‌های گزارش شده در این مقاله نشان‌دهنده بهبود روش پیشنهادی نسبت به روش‌های دیگر است. بار محاسباتی این روش، بر روی ماشین با مشخصات 3.2GHz Intel i7-3930K با ۸ هسته در حدود ۲-۴ ثانیه در CPU برای هر تصویر است.

• روش Geodesic<sup>۵</sup> [۲۲] توسط یک روش قطعه‌بندی تصویر پیشنهادی در مرجع [۱۲] شروع می‌شود. طبقه‌بندی‌ها از مکان Seeds برای تبدیل فاصله Geodesic<sup>۶</sup> استفاده می‌کنند. در این مقاله، Seeds توسط طبقه‌بند بهینه برای کشف اشیاء، آموزش داده شده است.

• در مراجع [۱۹ و ۲۰]<sup>۱</sup> یک قطعه‌بندی سلسله‌مراتبی از مرزهای انسداد<sup>۲</sup> و حل برش گراف با Seedها و پارامترهای متفاوت، برای تولید قطعات استفاده شده است. کانیدها براساس طیف گسترده‌ای از نشانه‌ها رتبه‌بندی شده است. این عمل در واقع سبب تشویق تنوع انتخابات می‌شود.

مراحل کلی پیشنهادشده در مقاله [۱۹] در شکل (۶) نشان داده شده است. در این روش، تصویر ورودی براساس روش سلسله‌مراتبی ارائه شده در [۲۱] قطعه‌بندی می‌شوند. این قطعه تولیدشده، ناحیه‌های Seed تصویر را به وجود می‌آوردند. در گام بعدی، با استفاده از این Seedها و ویژگی‌های مانند مرز، رنگ و بافت، مجموعه متنوعی از نواحی تولید می‌شود. این نواحی می‌توانند به عنوان قطعات شیء معرفی شوند. در نهایت با روش یادگیری ساخت یافته، ناحیه‌های به دست آمده رتبه‌بندی می‌شوند که به احتمال زیاد، مناطق با امتیاز بالاتر مربوط به اشیاء مختلف هستند. نتایج به دست آمده بر روی مجموعه داده BSDS<sup>۳</sup> و PASCAL VOC 2011 نشان‌دهنده توانایی این روش برای پیدا کردن اشیاء بیشتر با نواحی با اندازه کوچک در پنجره‌های کانیدهاست.

#### 4. Rigor

[http://cpl.cc.gatech.edu/projects/RIGOR/resources/rigor\\_src.zip](http://cpl.cc.gatech.edu/projects/RIGOR/resources/rigor_src.zip)

۵. منظور از فاصله Geodesic، اندازه کوتاه‌ترین مسیر بین نودهاست.

[http://www.philkr.net/papers/2014-10-01-eccv/gop\\_1.3.zip](http://www.philkr.net/papers/2014-10-01-eccv/gop_1.3.zip)


۶. منظور از تبدیل فاصله Geodesic، معیاری برای اندازه‌گیری کوتاه‌ترین مسیر بین مجموعه‌ای از نودها تا هر نود

#### 1. Endres

<https://github.com/Cloud-CV/object-proposals/tree/master/endres/proposals>


#### 2. occlusion

#### 3. Berkeley Segmentation Data Set



شکل (۷): مراحل کلی از روش Geodesic مطرح شده در مرجع [۲۲] الف. تصویر ورودی و بیش‌قطعه‌بندی آن به‌همراه نقشهٔ احتمال مرز، ب. مکان Seeds، پ. ماسک پیش‌زمینه و پس‌زمینهٔ تولیدشده برای دو Seeds، ج. استفاده از تبدیل فاصله Geodesic (SGDB) برای این ماسک‌ها، د. کاندیداهای پیشنهادی با توجه به محاسبه مجموعه‌های سطوح بحرانی در هر SGDB

یک تابع خطی دیگر برای پس‌زمینه آموزش داده شده است. نمونه‌ای از نتیجهٔ به‌دست‌آمده از روش پیشنهادی، بر روی مجموعه‌دادهٔ PASCAL VOC 2012 در شکل (۸) نشان داده شده است.



شکل (۸): اشیاء کاندیدا (نواحی قرمز) توسط الگوریتم [۲۲]

آزمایش‌های انجام‌شده در این مقاله، عملکرد بالا از لحاظ دقت و سرعت را روی مجموعه‌دادهٔ PASCAL VOC 2012 گزارش داده است.

• گروه‌بندی ترکیبی بر پایهٔ چندین مقیاس<sup>۶</sup> (MCG) [۲۸]: یک الگوریتم سریع برای محاسبهٔ قطعه‌بندی سلسله‌مراتبی چندین-مقیاسه<sup>۷</sup> که در مرجع [۱۲] معرفی شده، ارائه کرده است. قطعات براساس استحکام لبه<sup>۸</sup> ادغام می‌شوند. در نتیجه اشیاء براساس نشانه‌هایی مانند اندازه، مکان، شکل و استحکام لبه رتبه‌بندی شده‌اند.

ایدهٔ اصلی در این مقاله، معرفی مجموعه‌های سطوح بحرانی<sup>۱</sup> در تبدیل فاصلهٔ Geodesic است. تبدیل فاصلهٔ Geodesic برای مکان‌های Seeds در تصویر محاسبه شده است. تبدیل فاصله، در زمان نزدیک برخط<sup>۲</sup> محاسبه می‌شود. در این روش، محاسبهٔ اندازه‌گیری کوتاه‌ترین مسیر بین مجموعه‌ای از نودها تا هر نود ناچیز است. همچنین محاسبهٔ هر تبدیل برای تولید کاندیدها در مقیاس‌های متفاوت استفاده شده است. از این‌رو، استفاده از خط‌لوله<sup>۳</sup> در محاسبات، می‌تواند بسیار مؤثر باشد.

همان‌طور که در شکل (۷) نشان داده شده، در این روش ابرپیکسل‌های تصاویر ورودی با قطعه‌بندی محاسبه می‌شوند و نقشهٔ احتمال مرز<sup>۴</sup> به‌عنوان وزن گراف در نظر گرفته می‌شود. در واقع در این گراف هر نود به یک ابرپیکسل مربوط بوده و هر یال اتصال‌های بین ابرپیکسل‌های مجاور است. وزن یال‌ها میزان این تبدیل، به صورت کلی پس‌زمینه و پیش‌زمینه را مشخص می‌کند [۲۷]. هر مجموعه سطح<sup>۵</sup> از این تکنیک می‌تواند یک قطعه از تصویر را محدود کند که می‌تواند به‌عنوان اشیاء کاندیدا در نظر گرفته شوند. منظور از مجموعه سطح، مرز اشیاء موجود در پیش‌زمینه است. در این مقاله پیش‌زمینه و پس‌زمینهٔ به دست‌آمده از روش قبل با یک روش بر پایهٔ یادگیری بهبود داده شده است. در روش پیشنهادی، یک تابع خطی برای پیش‌زمینه و

6. Multiscale combinatorial grouping  
<https://github.com/jponttuset/mcg/archive/v2.0.zip>  
 7. Multi-scale  
 8. Edge Strength

1. Critical level sets  
 2. online  
 3. Pipeline  
 4. Boundary probability map  
 5. Level set



شکل (۱۰): نمونه‌ای از خروجی مرجع [۲۸]. قسمت بالای تصویر:

به ترتیب از سمت چپ: تصویر اصلی، نواحی هدف، قطعه‌بندی

سلسله‌مراتبی در چندین مقیاس، قسمت پایین تصویر: بهترین اشیاء

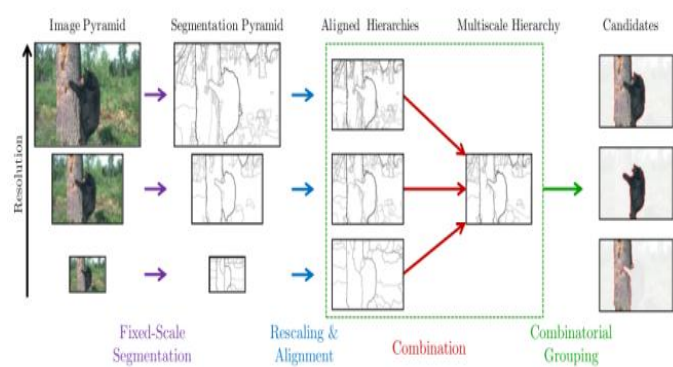
#### کاندیدا

تولید می‌کنند. در ادامه به معرفی بعضی از این روش‌ها می‌پردازیم.

- شی‌بودن [۲۹ و ۳۰] یکی از اولین و بهترین روش‌های شناخته‌شده در بحث روش‌های کاندیداهاست. یک مجموعه اولیه از کاندیداها از محل‌های برجسته در تصویر انتخاب می‌شود. این کاندیداها براساس چندین نشانه مانند رنگ، لبه‌ها، محل، اندازه و استحکام "Superpixel straddling (SS)" امتیازدهی می‌شوند. برای بررسی استحکام SS معیاری معرفی شده که میزان اشتراک بین ابرپیکسل و پنجره پیشنهادی را محاسبه می‌کند.

- Rahtu [۳۱] از مجموعه‌ای از ناحیه‌های کاندیدا با انتخاب تصادفی استفاده می‌کند. این نواحی توسط ابرپیکسل‌های منحصربه‌فرد، جفت یا سه‌تایی به دست می‌آیند. این ابرپیکسل‌ها چندین محدوده با انتخاب تصادفی دارند. استراتژی امتیازدهی بازبینی شده و بهبودهایی در آن ارائه شده است.

- Bing [۳۲] از یک طبقه‌بند خطی ساده با ویژگی‌های لبه استفاده می‌کند. در این روش، از پنجره لغزان استفاده شده است. سرعت تخمین در این روش بسیار بالاست. در این روش، طبقه‌بند تأثیر اندکی دارد و می‌تواند عملکردی مشابه با



شکل (۹): مراحل کلی از روش پیشنهادی در [۲۸]

مراحل کلی روش پیشنهادی در شکل (۹) نشان داده شده است. این روش، ابتدا از هرمی در چندین وضوح<sup>۱</sup> تصویر شروع می‌شود. در گام بعدی، قطعه‌بندی سلسله‌مراتبی در هر مقیاس، به صورت مستقل صورت می‌گیرد. سپس تصاویر حاصل از سلسله‌مراتبی چندگانه تراز می‌شوند و تصاویر تولیدی در یک تصویر قطعه‌بندی شده با چندین مقیاس تنها ترکیب می‌شوند. در نهایت با گروه‌بندی اجزای حاصل، فهرست امتیازاتی از اشیاء کاندیدا با جستجو در ناحیه‌های فضای ترکیبی محاسبه می‌شود.

این روش بر روی مجموعه داده PASCAL VOC 2012 و BSDS500 مورد ارزیابی قرار گرفته است و عملکرد مناسبی از این روش گزارش شده است. نمونه‌ای از نتایج به دست آمده در شکل (۱۰) نشان داده شده است.

## ۲.۲. روش‌های امتیاز دادن به پنجره کاندیدا

یک روش جایگزین برای تولید کاندیداها، امتیازدهی هر پنجره کاندیداهاست. در واقع هر تصویر پنجره‌گذاری شده و در گام بعدی به هر پنجره امتیازدهی براساس احتمال شی‌بودن پنجره کاندیدا صورت می‌گیرد. در مقایسه با روش‌های گروه‌بندی، این روش‌ها معمولاً فقط مرز محدوده‌ها را برگشت می‌دهند و سریع‌تر هستند. در مواردی که نمونه‌گیری پنجره با تعداد بالا باشد، این روش‌ها معمولاً پیشنهادهای با دقت محلی‌سازی پایین

2. <http://groups.inf.ed.ac.uk/calvin/objectness/objectness-release-v۲,۲.zip>

3. [http://www.ee.oulu.fi/research/imag/object\\_detection/ObjectnessICCV\\_ver۰۲.zip](http://www.ee.oulu.fi/research/imag/object_detection/ObjectnessICCV_ver۰۲.zip)

4. <https://github.com/tfzhou/BINGObjectness/archive/master.zip>



PASCAL VOC 2007 تخمین زده می‌شوند سپس ۵/۰ درصد از کوچک‌ترین و بزرگ‌ترین مقادیر نادیده گرفته می‌شوند و توزیع تخمین‌زده شده ۹۹ درصد از داده‌ها را پوشش می‌دهد.

• روش گاوسی<sup>۸</sup>: به همین ترتیب، یک توزیع گاوسین چندمتغیره برای موقعیت مرکز محدوده مرزبندی، ناحیه ریشه مربع و لگاریتم نسبت ابعاد تخمین‌زده می‌شود. در گام بعدی، مقدار میانگین و واریانس در مجموعه آموزشی محاسبه می‌شود. در نهایت کاندیداها از این توزیع‌ها نمونه‌برداری شده‌اند.

• روش پنجره لغزان: در این روش پنجره در یک شبکه (گرید) منظم مکان‌یابی می‌شود که برای آشکارسازی شیء در پنجره لغزان رایج است. تعداد درخواست کاندیداها براساس اندازه پنجره توزیع شده است. برای هر اندازه پنجره به صورت یکنواخت پنجره‌ها مکان‌یابی شده‌اند. این روش از پیاده‌سازی مراجع [۳۲ و ۳۳] الهام گرفته شده است.

• روش ابریکیسل: همان‌طور که در قسمت‌های قبل بیان شد، ابریکیسل تأثیر مهمی روی رفتار روش‌های پیشنهادی دارند. باتوجه‌به تعریف مرجع [۳۸]، ابریکیسل به نواحی اتمیک<sup>۹</sup> متراکم یا به‌هم‌پیوسته<sup>۱۰</sup> و ادراکی<sup>۱۱</sup> معنادار<sup>۱۲</sup> در گفته می‌شود.

### ۳. کنترل تعداد کاندیداهای پیشنهادی

برای مقایسه جامع بین روش‌های مطرح‌شده باید تعداد کاندیداهای ارائه‌شده در هر تصویر توسط روش‌هایی کنترل شوند؛ زیرا برای مقایسه صحیح بین روش‌های موجود باید تعداد کاندیداهای ارائه‌شده یکسان باشد. در بسیاری از موارد، روش‌ها با ارائه تعداد کاندیداها بین صد تا صدهزار مورد ارزیابی قرار می‌گیرند. همچنین برخی از روش‌ها امتیاز کاندیداها را ارائه داده و در مقابل بعضی دیگر این توانایی را

زمانی را که به تصویر نگاه نمی‌شود [۳۳] داشته باشد. این روش‌های مستقل از تصویر، با نام CrackingBing معروف هستند.

• EdgeBoxes<sup>۱۷</sup> [۷] همچنین از یک الگو پنجره لغزان بزرگ<sup>۱۸</sup> شروع می‌شود. اما براساس تخمین مرز اشیاء که توسط ساختار جنگل تصمیم [۱۴ و ۳۴] به‌دست آمده، ساخته شده است و یک گام پالایش<sup>۱۹</sup> بعدی را برای افزایش محلی‌سازی اضافه می‌کند. در این روش، پارامتری یاد گرفته نمی‌شود.

### ۲.۳. روش‌های کاندیدا جایگزین<sup>۴</sup>

• ShapeSharing [۳۵] یک روش غیر پارامتریک<sup>۵</sup> و مبتنی‌بر داده است که شکل‌های اشیاء را از نمونه‌های درون تصاویر آزمون توسط انطباق لبه‌ها استخراج می‌کند. در نتیجه نواحی در مرحله بعد ادغام می‌شوند و به‌وسیله حل کردن برش گراف اصلاح می‌شوند.

• Multibox [۳۶ و ۳۷] یک شبکه عصبی را برای برگرداندن تعداد ثابتی از کاندیداها به صورت مستقیم آموزش داده است. در واقع شبکه بر روی تصویر ورودی لغزانه نشده است. نویسنده بهترین نتایج بر روی دادگان ImageNet را گزارش داده است.

### ۲.۴. روش‌های پایه یا مرجع<sup>۶</sup> در پیشنهاد کاندیدا

بعضی از روش‌ها به‌عنوان روش پایه و نقاط مرجع معرفی می‌شوند. تمامی این روش‌ها، در قسمت‌های قبل مورد استفاده قرار گرفته‌اند. از روش‌های زیر، به‌عنوان روش پایه استفاده می‌شود.

• روش یکنواخت<sup>۷</sup>: در این روش برای تولید کاندیدا، به‌صورت یکنواخت موقعیت مرکز محدوده مرزبندی، ناحیه ریشه مربع و لگاریتم نسبت ابعاد، نمونه‌برداری می‌شوند. در گام بعدی، بازه‌ای از این پارامترها با مجموعه آموزش

1. <https://github.com/pdollar/edges/archive/master.zip>

2. coarse

3. refinement

4. Alternative Proposal Methods

5. Non-parametric

6. Baseline

7. Uniform

8. Gaussian

9. atomic

10. compact

11. perceptually

12. meaningful

بعضی از روش‌ها کاندیداهای تکراری تولید می‌کنند که آن‌ها را باید از مجموعه انتخابی در هر روش پاک نمود. مقایسه بین روش‌های ارائه شده از لحاظ کنترل پذیر بودن تعداد کاندیداها در جدول (۱) نشان داده شده است. همچنین در این جدول مقایسه‌ای بین روش‌ها از لحاظ نوع روش و خروجی حاصل صورت گرفته است.

#### ۴. مجموعه داده

در سال‌های اخیر، تحقیقات و آزمایش‌های بسیاری در زمینه انتخاب ناحیه‌های کاندیدا، تشخیص و شناسایی اشیاء بر روی تصاویر انجام شده است. معمولاً این تحقیقات بر روی مجموعه داده استاندارد بوده که ارزیابی روش‌های پیشنهادی را با دقت بیشتری امکان‌پذیر می‌سازد. از مهم‌ترین مجموعه داده‌های استفاده شده در سال‌های اخیر می‌توان به PASCAL، ImageNet و MS COCO اشاره کرد. در ادامه به معرفی هریک از مجموعه داده‌ها پرداخته شده و ویژگی هریک به تفصیل بیان می‌شود.

ImageNet: این مجموعه داده بزرگ‌ترین و گسترده‌ترین مجموعه تصاویر تهیه شده از وب است که برای تشخیص و شناسایی اشیاء مورد استفاده قرار گرفته شده است. این مجموعه شامل تقریباً ۳/۲ میلیون تصویر در ۵۲۴۷ کلاس متفاوت است. در تحقیقاتی که تاکنون انجام شده، تعداد محدودی از این مجموعه داده، مورد استفاده قرار گرفته است. مجموعه داده‌ای که در این تحقیق مورد بررسی قرار می‌گیرد، مجموعه اعتبارسنجی ImageNet 2013 است که شامل ۲۰۰ کلاس متفاوت و تقریباً بالغ بر ۲۰۰۰۰ تصویر از این کلاس‌ها است.

PASCAL: این مجموعه داده شامل ۲۰ کلاس متفاوت است که تقریباً شامل ۵۰۰۰ تصویر نامحدود در حالت‌های مختلف از این کلاس‌هاست.

MS COCO: دو مجموعه داده معرفی شده (ImageNet و PASCAL) برای مقایسه اگرچه از نظر تعداد کلاس‌ها

ندارند. البته نمی‌توان در همه روش‌ها به صورت صریح و روشن تعداد کاندیداها را کنترل کرد. در روش‌هایی که امتیاز کاندیدا را ارائه می‌دهند،  $k$  برترین ناحیه کاندیدا انتخاب می‌شوند. ولی در برخی از روش‌ها، نمی‌توان کنترل مستقیم بر روی تعداد کاندیداها داشت و همچنین امتیاز کاندیداها نیز مشخص نمی‌شوند. در این روش‌ها می‌توان با کنترل غیرمستقیم به  $k$  کاندیدا دسترسی داشت. در این خصوص نیاز است که پارامترهای دیگر را تغییر داد تا به این کنترل دسترسی پیدا کرد. به همین سبب تعداد کاندیداهای تولید شده با پارامترهای متفاوت در زیرمجموعه‌ای از تصویر ذخیره می‌شود. در نهایت با استفاده از یک درونیابی خطی بین تنظیم‌های پارامترها،  $k$  کاندیدا انتخاب می‌شوند. در بعضی از روش‌ها که هیچ کنترلی روی تعداد کاندیداها امکان‌پذیر نیست،  $k$  نمونه به صورت تصادفی انتخاب می‌شود.

جدول (۱): مقایسه‌ای بین روش‌های معرفی شده. علامت +/- به معنی، دارا بودن یا نبودن خاصیت مشخص است و علامت \* در کنترل تعداد کاندیدا، نشان‌دهنده کنترل غیرمستقیم است.

روش	نوع روش	خروجی قطعات	خروجی امتیاز	کنترل
Bing[18]	پنجره لغزان	-	+	+
CPMC[19]	گروه‌بندی	+	+	*
EdgeBox[20]	پنجره لغزان	-	+	+
Endres[21]	گروه‌بندی	+	+	+
Geodesic[22]	گروه‌بندی	+	-	*
MCG[23]	گروه‌بندی	+	+	*
Objectness[24]	پنجره لغزان	-	+	+
Rahtu[25]	پنجره لغزان	-	+	+
RandPrim[26]	گروه‌بندی	+	-	+
Rantalankila[27]	گروه‌بندی	+	-	*
Rigor[29]	گروه‌بندی	+	-	*
SelectiveSearch[30]	گروه‌بندی	+	+	*
Gussian	-	-	-	+
SlidingWindow	-	-	-	+
Superpixels	-	+	-	-
Uniform	-	-	-	+

۶۰ درصد از داده‌ها برای آموزش و ۴۰ درصد باقی‌مانده برای آزمون در نظر گرفته شده‌اند. در واقع نتایج ارائه‌شده بر پایه نتایج حاصل از مجموعه‌داده آزمون است. در روش‌های مطرح‌شده، روش‌های Bing, MCG, Rahtu, EdgeBoxes, Randomized Selective Search, Endres, CPMC و Prims و Ranta نیاز به آموزش داشته و مرحله آموزش به صورت جداگانه انجام شده است. شکل (۱۱) نتایج به دست آمده از روش R-CNN سریع با روش‌های پیشنهاد کاندیدای متفاوت در هر کلاس را نشان می‌دهد. باتوجه به نتایج به دست آمده روش‌های EdgeBox و MCG در این مجموعه داده بر روی اکثر کلاس‌ها دارای بهترین نتایج بوده و عملکرد مناسبی را از خود نشان داده‌اند. نواحی کاندیدی که این دو روش ارائه داده‌اند، توسط شبکه RCNN بهترین نتیجه در برچسب‌گذاری اشیاء موجود از خود ارائه داده‌اند. در روش‌های پیشنهاد کاندیدا، تعداد ناحیه‌های پیشنهادی در این آزمایش، ۲۰۰۰ ناحیه لحاظ شده‌اند. باتوجه به نتایج به دست آمده روش R-CNN سریع با نواحی کاندیدا در اشکالی مانند بطری و گیاه نتایج خوبی از خود نشان نداده است، ولی در مواردی مانند قطار، اسب، گربه و ماشین این روش نتایج قابل قبولی را از خود نشان داده است.


متفاوت بوده، از نظر آماری از لحاظ تعداد اشیای موجود در هر تصویر و اندازه اشیاء شبیه هم هستند.

مجموعه‌داده MS COCO شامل ۸۰ کلاس متفاوت از اشیاء است، ولی دارای اشیاء بیشتر و اندازه متفاوت‌تر (کوچک‌تر) در هر تصویر نسبت به دو مجموعه‌داده دیگر است.

## ۵. مقایسه بین روش‌های موجود

همان‌طور که در قسمت مقدمه بیان شد، یکی از چالش‌های اساسی و تأثیرگذار در بحث شناسایی اشیاء، پیشنهاد ناحیه‌های کاندیدا بوده است. از طرفی، یکی از روش‌های موفق و مشهور مطرح در زمینه شناسایی، روش R-CNN سریع بوده که توسط دانشگاه MIT پیاده‌سازی شده است. در همین راستا به بررسی تأثیر روش پیشنهاد کاندیدا بر روی این سیستم شناسایی پرداخته شده است. در آزمایش اول از مجموعه داده PASCAL VOC 2007 برای ارزیابی کلاس‌های موجود در این مجموعه داده به صورت جداگانه استفاده شده است. معیار ارزیابی استفاده شده در این مقاله، معیار دقت برچسب‌گذاری اشیاء بر پایه نواحی کاندیدی پیشنهادی است. در معیار دقت، نسبت برچسب‌های صحیح تشخیص داده‌شده اشیاء به تمامی اشیاء در نظر گرفته شده است.

برخی از روش‌های مطرح شده، نیاز به مرحله آموزش داشته‌اند. در همین راستا، در مجموعه‌داده‌های معرفی‌شده،



شکل (۱۱): مقایسه بین روش‌های پیشنهاد کاندیدا بر روی مجموعه‌داده PASCAL VOC 2007 با روش R-CNN سریع

(۲)، بار محاسباتی مناسب‌تری دارند و روش‌های Bing و EdgeBoxes بهترین عملکرد زمانی را دارند.

جدول (۲): مقایسه زمان متوسط اجرای روش‌های پیشنهاد کاندیدا بر


روی هر تصویر PASCAL VOC 2007

زمان بر حسب ثانیه	روش
۳	Objectness
۲۵۰	CPMC
۱۰۰	Endres
۱۰	Selective Search
۳	Rahtu
۱	Randomized Prims
۰٫۲	Bing
۳۰	MCG
۱۰	Ranta
۰٫۳	EdgeBoxes
۱	Superpixels

## ۶. نتیجه‌گیری

یکی از تنگناهای محاسباتی در سیستم‌های تشخیص و شناسایی اشیاء در تصویر، به‌دست‌آوردن ناحیه‌های کاندیدا هستند. در واقع عملکرد این نوع سیستم‌ها به روش انتخاب نواحی کاندیدا وابسته است. در همین راستا در این مقاله به معرفی و مقایسه روش‌های ناحیه‌های کاندیدا پرداخته شده و بررسی شد که این روش‌ها در یک مجموعه داده یکسان، چه عملکردی را از خود نشان می‌دهند. به‌منظور مقایسه این روش‌ها از یک سیستم شناسایی مشهور و محبوب R-CNN سریع که مورد استقبال بسیاری از محققان و پژوهشگران در این زمینه بوده، استفاده شده است. با توجه به نتایج به‌دست‌آمده، استفاده از روش‌های پایه و مرجع به‌تنهایی عملکرد خوبی نداشته است و روش‌های EdgeBoxes و MCG بهترین نتایج را بر روی مجموعه‌داده‌های استاندارد از خود نشان داده‌اند.

در آزمایش دوم، از سه مجموعه‌داده استفاده شده است. شکل (۱۲) نتایج به‌دست‌آمده بر روی مجموعه PASCAL 2007، ImageNet 2013 و MS COCO را با هزار ناحیه کاندیدا را نشان می‌دهد. با توجه به نتایج به‌دست‌آمده در هر سه مجموعه داده روش MCG بهترین نتایج را از خود نشان داده و روش‌های مرجع و پایه مانند ابرپیکسل، پنجره لغزان و گوسی به‌تنهایی نتایج قابل‌قبولی را از خود نشان نمی‌دهند.



شکل (۱۲): نتایج به‌دست‌آمده روی سه مجموعه‌داده متفاوت براساس ۱۰۰۰ ناحیه کاندیدا و روش‌های متفاوت کاندیدا

در ادامه برای ارزیابی بهتر روش‌های پیشنهاد کاندیدا، زمان اجرای این الگوریتم برای متوسط هر تصویر محاسبه شده است. این زمان‌ها در جدول (۲) آورده شده است. با توجه به نتایج جدول (۲)، روش‌هایی مانند CPMC، Endres، جستجوی انتخابی، Ranta، MCG، بار محاسبات نسبتاً بالایی دارند و معمولاً برای شناسایی برخی اشیاء مناسب نیستند. ولی بقیه روش‌های ارائه‌شده در جدول

## مراجع

- [1] He, K., et al., *Spatial pyramid pooling in deep convolutional networks for visual recognition*. Pattern Analysis and Machine Intelligence, IEEE Transactions on, 2015. 37(9): p. 1904-1916.
- [2] Ren, S., et al. *Faster R-CNN: Towards real-time object detection with region proposal networks*. in

*Advances in Neural Information Processing Systems*. 2015.

- [3] Girshick, R., et al. *Rich feature hierarchies for accurate object detection and semantic segmentation*. in *Proceedings of the IEEE conference on computer vision and pattern*

- recognition. 2014.
- [4] Girshick, R. *Fast r-cnn*. in *Proceedings of the IEEE International Conference on Computer Vision*. 2015.
- [5] Simonyan, K. and A. Zisserman, *Very deep convolutional networks for large-scale image recognition*. arXiv preprint arXiv:1409.1556, 2014.
- [6] Uijlings, J.R., et al., *Selective search for object recognition*. International journal of computer vision, 2013. 104(2): p. 154-171.
- [7] Zitnick, C.L. and P. Dollár, *Edge boxes: Locating object proposals from edges*, in *Computer Vision–ECCV 2014*. 2014, Springer. p. 391-405.
- [8] Van de Sande, K.E., et al. *Segmentation as selective search for object recognition*. in *Computer Vision (ICCV), 2011 IEEE International Conference on*. 2011. IEEE.
- [9] Felzenszwalb, P.F. and D.P. Huttenlocher, *Efficient graph-based image segmentation*. International Journal of Computer Vision, 2004. 59(2): p. 167-181.
- [10] Van den Bergh, M., et al., *Seeds: Superpixels extracted via energy-driven sampling*. International Journal of Computer Vision, 2015. 111(3): p. 298-314.
- [11] Arbelaez, P., et al., *Contour detection and hierarchical image segmentation*. Pattern Analysis and Machine Intelligence, IEEE Transactions on, 2011. 33(5): p. 898-916.
- [12] Dollár, P. and C.L. Zitnick, *Fast edge detection using structured forests*. Pattern Analysis and Machine Intelligence, IEEE Transactions on, 2015. 37(8): p. 1558-1570.
- [13] Geusebroek, J.-M., et al., *Color invariance*. Pattern Analysis and Machine Intelligence, IEEE Transactions on, 2001. 23(12): p. 1338-1350.
- [14] Manen, S., M. Guillaumin, and L. Gool. *Prime object proposals with randomized prim's algorithm*. in *Proceedings of the IEEE International Conference on Computer Vision*. 2013.
- [15] Rantalankila, P., J. Kannala, and E. Rahtu. *Generating object segmentation proposals using global and local search*. in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2014.
- [16] Chang, K.-Y., et al. *Fusing generic objectness and visual saliency for salient object detection*. in *Computer Vision (ICCV), 2011 IEEE International Conference on*. 2011. IEEE.
- [17] Carreira, J. and C. Sminchisescu. *Constrained parametric min-cuts for automatic object segmentation*. in *Computer Vision and Pattern Recognition (CVPR), 2010 IEEE Conference on*. 2010. IEEE.
- [18] Carreira, J. and C. Sminchisescu, *Cpmc: Automatic object segmentation using constrained parametric min-cuts*. Pattern Analysis and Machine Intelligence, IEEE Transactions on, 2012. 34(7): p. 1312-1328.
- [19] Endres, I. and D. Hoiem, *Category-independent object proposals with diverse ranking*. Pattern Analysis and Machine Intelligence, IEEE Transactions on, 2014. 36(2): p. 222-234.
- [20] Endres, I. and D. Hoiem, *Category independent object proposals*, in *Computer Vision–ECCV 2010*. 2010, Springer. p. 575-588.
- [21] Hoiem, D., A.A. Efros, and M. Hebert, *Recovering occlusion boundaries from an image*. International Journal of Computer Vision, 2011. 91(3): p. 328-346.
- [22] Krähenbühl, P. and V. Koltun, *Geodesic object proposals*, in *Computer Vision–ECCV 2014*. 2014, Springer. p. 725-739.
- [23] Humayun, A., F. Li, and J. Rehg. *RIGOR: reusing inference in graph cuts for generating object regions*. in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2014.
- [24] Lim, J., C. Zitnick, and P. Dollár. *Sketch tokens: A learned mid-level representation for contour and object detection*. in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2013.
- [25] Yatziv, L., A. Bartesaghi, and G. Sapiro, *O (N) implementation of the fast marching algorithm*. Journal of computational physics, 2006. 212(2): p. 393-399.
- [26] Toivanen, P.J., *New geodesic distance transforms for gray-scale images*. Pattern Recognition Letters, 1996. 17(5): p. 437-450.
- [27] Bai, X. and G. Sapiro, *Geodesic matting: A framework for fast interactive image and video segmentation and matting*. International journal of computer vision, 2009. 82(2): p. 113-132.
- [28] Arbeláez, P., et al. *Multiscale combinatorial grouping*. in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2014.
- [29] Alexe, B., T. Deselaers, and V. Ferrari. *What is an object?* in *Computer Vision and Pattern Recognition (CVPR), 2010 IEEE Conference on*. 2010. IEEE.
- [30] Alexe, B., T. Deselaers, and V. Ferrari, *Measuring the objectness of image windows*. Pattern Analysis and Machine Intelligence, IEEE Transactions on, 2012. 34(11): p. 2189-2202.
- [31] Rahtu, E., J. Kannala, and M. Blaschko. *Learning a category independent object detection cascade*. in *Computer Vision (ICCV), 2011 IEEE International Conference on*. 2011. IEEE.
- [32] Cheng, M.-M., et al. *BING: Binarized normed gradients for objectness estimation at 300fps*. in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2014.
- [33] Zhao, Q., Z. Liu, and B. Yin. *Cracking BING and*

- Beyond*. in *BMVC*. 2014.
- [34] Dollár, P. and C. Zitnick. *Structured forests for fast edge detection*. in *Proceedings of the IEEE International Conference on Computer Vision*. 2013.
- [35] Kim, J. and K. Grauman, *Shape sharing for object segmentation*, in *Computer Vision–ECCV 2012*. 2012, Springer. p. 444-458.
- [36] Erhan, D., et al. *Scalable object detection using deep neural networks*. in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2014.
- [37] Szegedy, C., et al., *Scalable, high-quality object detection*. arXiv preprint arXiv:1412.1441, 2014.
- [38] Yan, J., et al. *Object detection by labeling superpixels*. in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2015.

دریافت مقاله: ۱۳۹۴/۰۸/۲۶

پذیرش مقاله: ۱۳۹۶/۰۳/۳۱

## آموزش شبکه عصبی مصنوعی با نسخه آشوب گونه الگوریتم جستجوی گرانشی و کاربرد آن در پیش بینی آلاینده های هوا: مطالعه قیاسی

منصور شیخان<sup>۱\*</sup>، زهرا جعفری نسب<sup>۲</sup>

دانشیار، گروه مهندسی برق، دانشگاه آزاد اسلامی، واحد تهران جنوب، تهران، ایران

msheikhn@azad.ac.ir

کارشناس ارشد، گروه مهندسی کامپیوتر، دانشگاه آزاد اسلامی، واحد تهران جنوب، تهران، ایران

z\_jafari\_n@yahoo.com

چکیده: امروزه پیش بینی آلودگی هوا در نواحی شهری، به دلیل تأثیر آن بر روی سلامتی انسان، یکی از موضوعات مهم در پژوهش های زیست محیطی است. با وجود اهمیت بسزای موضوع آلودگی هوا، داده های نقاط اندکی در دسترس بوده و اندازه گیری آن برای تمام نقاط مورد نظر ناممکن است. به همین علت، تاکنون مدل های مختلفی برای پیش بینی آلودگی هوا معرفی شده اند. در این مقاله، ۱۰ ویژگی مهم از مجموع ۲۰ ویژگی مربوط به داده های سازمان هواشناسی و مؤثر در پیش بینی آلودگی هوا، توسط نسخه دودویی الگوریتم جستجوی گرانشی انتخاب شده اند. در ادامه، با استفاده از نسخه آشوب گونه الگوریتم جستجوی گرانشی، یک شبکه عصبی به منظور پیش بینی آلاینده های هوای شهر تهران آموزش داده شده است. برای ارزیابی کارایی شبکه عصبی آموزش دیده، عملکرد آن در پیش بینی میزان آلاینده های هوای شهر تهران، در شرایط کاملاً یکسان با پنج روش دیگر که در آن ها شبکه عصبی با الگوریتم های جستجوی گرانشی استاندارد، پستشار خطا، اجتماع زنبورها، ترکیب الگوریتم های وراثتی با تبرید شبیه سازی شده، و بهینه سازی ازدحام ذرات آموزش دیده است، مقایسه می شود. نتایج تجربی گویای برتری روش پیشنهادی در آموزش شبکه عصبی با هدف پیش بینی آلودگی است.

واژه های کلیدی: آموزش شبکه عصبی، انتخاب ویژگی، نسخه آشوب گونه الگوریتم جستجوی گرانشی، آلودگی هوا.

## ۱. مقدمه

سیستم‌هایی با رفتار پیچیده دارند. پس می‌توان از آن‌ها برای پیش‌بینی میزان غلظت آلاینده‌های هوا با استفاده از پارامترهای هواشناسی استفاده کرد.

در ادامه، کارهای مرتبط در این حوزه و نوآوری روش پیشنهادی در این مقاله (در مقایسه با پژوهش‌های قبلی) ارائه خواهند شد. در ادامه، داده‌های ورودی به مدل پیش‌بین معرفتی و چگونگی پیش‌پردازش داده‌ها بیان خواهد شد. سپس الگوریتم‌های مورداستفاده برای آموزش شبکه عصبی معرفتی شده و در ادامه، نتایج شبیه‌سازی با مجموعه داده‌های سازمان هواشناسی ارائه و نتایج، مورد بحث و بررسی قرار می‌گیرند.

## ۲. کارهای مرتبط و نوآوری روش پیشنهادی

ارتباط بین میزان غلظت  $O_3$  و شرایط آب‌وهوایی و به‌دنبال آن، امکان پیش‌بینی  $O_3$  از داده‌های هواشناسی در بسیاری از پژوهش‌های قبلی گزارش شده است [۴ و ۵]. در این باره، روش‌های آماری [۸-۶]، رگرسیون خطی چندگانه [۹]، سامانه‌های فازی [۱۰] و [۱۱]، شبکه عصبی مصنوعی پرسپترون چندلایه (MLP) [۱۲-۱۴]، شبکه عصبی پایه-شعاعی (RBF) [اصلاحی ۵]، ترکیبی از چند شبکه عصبی MLP [۱۵]، مدل ANFIS [۱۲] و شبکه عصبی بازگشتی (RNN) [۱۶] مورداستفاده قرار گرفته‌اند. در موضوع تخمین غلظت آلاینده‌ها در کلان‌شهرهای کشور نیز می‌توان برای نمونه به پژوهش‌هایی درخصوص تخمین و ارزیابی غلظت آلاینده‌ها در مجاورت بزرگراه‌ها [۱۷] و تأثیر طوفان‌های گرد و غبار خاورمیانه بر غلظت آلاینده‌ها [۱۸] اشاره کرد. همچنین م. ارحامی و همکاران [۱۹] برای بهینه‌سازی مدل شبکه عصبی پیش‌بین غلظت آلاینده‌های هوای شهر تهران، تحلیل عدم قطعیت‌ها براساس شبکه عصبی و شبیه‌سازی‌های مونت‌کارلو را انجام دادند. متغیرهای ورودی به شبکه عصبی مصنوعی نیز سرعت باد، دما، رطوبت نسبی و جهت باد در نظر گرفته شده‌اند.

آلودگی هوا را می‌توان این‌گونه تعریف کرد: «وجود هر نوع آلاینده اعم از جامد، مایع، گاز یا تشعشع پرتوزا و غیرپرتوزا در هوا، به مقدار و در مدت‌زمانی که کیفیت زندگی را برای انسان و دیگر جانداران به خطر اندازد و یا به آثار باستانی و اموال خسارت وارد آورد» [۱]. امروزه مشکلات ناشی از آلودگی هوا در کلان‌شهرها، به یک چالش زیست‌محیطی تبدیل شده است. این مشکل در کلان‌شهرها به دلیل حجم ترافیکی سنگین ناشی از ترابری، استفاده از خودروهای غیراستاندارد و احتراق ناقص سوخت‌های مورداستفاده خودروها اهمیت ویژه‌ای دارد [۲].

آلاینده‌های اصلی هوا که برای آن‌ها استاندارد وجود دارد و اندازه‌گیری می‌شوند، عبارت است از [۳]: منوکسیدکربن (CO)، اکسیدهای ازت (NOx)، تمامی هیدروکربن‌ها (THC) یا ترکیبات آلی فرار (VOC)، اکسیدهای گوگرد (SOx)، تمامی ذرات معلق (TSP)، سرب (Pb) و ازن ( $O_3$ ).

یکی از عوامل مهم آلودگی هوا در اغلب شهرهای بزرگ، گاز ازن در سطح زمین است. ازن در سطح زمین هنگامی تشکیل می‌شود که گازهای آلاینده حاصل از خودروها و سایر وسایلی که سوخت مصرف می‌کنند، با نور خورشید واکنش می‌دهد؛ در نتیجه گاز ازنی به وجود می‌آید که برای انسان سمی است.

باتوجه به ماهیت غیرخطی آلودگی هوا و تأثیرپذیری از پارامترهای طبیعی مختلف، پیش‌بینی میزان آلاینده‌ها بسیار دشوار بوده و نیاز به استفاده از پارامترهای هواشناسی و مکانی مختلفی دارد. برای این منظور، روابط و روش‌های گوناگونی پیشنهاد شده‌اند که هرکدام در یک منطقه یا در یک شرایط خاص، نتایج مطلوبی ارائه کرده‌اند. مدل‌های پیش‌بینی آلودگی هوا وسیله بسیار مؤثری هستند که به کمک آن‌ها می‌توان برای مدیریت آلودگی هوای کلان‌شهرها، رویکردهای مناسب و کم‌هزینه را طرح‌ریزی کرد.

شبکه‌های عصبی مصنوعی می‌توانند با استفاده از داده‌های تجربی، رفتار سیستم را یافته و به‌عنوان مدل پیش‌بین به‌کار روند. این شبکه‌ها قابلیت بسیار خوبی در مدل‌سازی

1. Multi-Layer Perceptron
2. Radial-Basis Function
3. Adaptive Neuro-Fuzzy Inference System
4. Recurrent Neural Network



درباره نوآوری پژوهش حاضر در مقایسه با پژوهش‌های مرتبط در سالیان اخیر، می‌توان به موارد زیر اشاره کرد:

الف. در مرجع [۱۶]، از ۶ ویژگی (میزان غلظت  $\text{NO}_2$ ، دما، رطوبت نسبی، سرعت باد، جهت باد و میزان تشعشع خورشیدی) به صورت مستقیم به عنوان ورودی استفاده شده است. حال آنکه در پژوهش اخیر، از گستره وسیع تری از داده‌های ورودی (۲۰ ویژگی) بهره گرفته شده است که از این بین، به کمک الگوریتم جستجوی گرانشی دودویی (BGSA)<sup>۱</sup>، ۱۰ ویژگی بهینه انتخاب شده‌اند. شایان ذکر است که این موضوع فراتر از ازدیاد صرف و بدون رویه تعداد ورودی‌هاست. مشکل موجود در موضوع این مقاله، وابسته بودن پیش‌بینی به تعداد زیادی از متغیرها و درعین حال، عدم تمایل به داشتن مدلی با تعداد ورودی‌های زیاد (که آن را پیچیده کند) می‌باشد. لذا انتخاب ویژگی با روش پیشنهادی، یکی از نوآوری‌های این مقاله برای غلبه بر این مشکل است که در پژوهش‌های قبلی گزارش نشده است.

ب. شاید نزدیک‌ترین پژوهش‌های انجام‌شده به پژوهش حاضر، از لحاظ به کارگیری روش‌های ترکیبی و پیش‌بینی غلظت آلاینده‌های هوا توسط شبکه‌های عصبی، روش‌های پیشنهادی در مراجع [۲۰ و ۲۱] باشد. در مرجع [۲۰]، یک واحد استخراج معرفت (KD)<sup>۲</sup> همراه با شبکه عصبی به کار گرفته شده است تا سهم/اهمیت هریک از ورودی‌ها را در میزان متغیر موردپیش‌بینی (از طریق محاسبه صرف یک ضریب اهمیت) تعیین کند (شبه همان کاری که در پژوهش حاضر با به کارگیری واحد انتخاب ویژگی مبتنی بر روش هوشمند BGSA انجام می‌شود). به همین ترتیب در مرجع [۲۱]، از روش سنتی تحلیل مؤلفه اصلی (PCA)<sup>۳</sup> برای انتخاب ورودی‌ها به شبکه عصبی و ماشین بردار پشتیبان (SVM)<sup>۴</sup> به عنوان دو ابزار پیش‌بینی میزان غلظت آلاینده  $\text{O}_3$  استفاده شده است. حال آنکه در مقاله حاضر، از روش هوشمند و نوین تر BGSA برای انتخاب ویژگی و نیز نسخه آشوب‌گونه الگوریتم جستجوی گرانشی (CGSA)<sup>۵</sup> برای

آموزش شبکه عصبی مصنوعی (به جای روش استاندارد پس‌انتشار خطا) استفاده شده و مقایسه نتایج با روش‌های مرتبط رقیب نیز صورت پذیرفته است.

شایان ذکر است که آموزش شبکه عصبی مصنوعی با الگوریتمی مناسب از چالش‌های به کارگیری این مدل در کاربردهای پیش‌بینی است. با توجه به مشکل روش سنتی پس‌انتشار خطا (EBP)<sup>۶</sup> در آموزش (یعنی گرفتاری در کمینه‌های محلی)، استفاده از روش‌های هوش محاسباتی در بسیاری از پژوهش‌های اخیر توصیه شده است. به کارگیری CGSA در این مقاله، نتایج مناسبی را در مقایسه با روش‌های رقیب ارائه نموده است.

پ. موضوع به کارگیری CGSA در بهینه‌سازی ساختار مدل‌ها نیز در مورد مدل رگرسیون بردار پشتیبان<sup>۷</sup> (SVR) [۲۲]، مدل فازی تاکاگی-سوگنو<sup>۸</sup> [۲۳] و شناسایی پارامترهای یک سیستم آشوبناک<sup>۹</sup> [۲۴] گزارش شده است. اما براساس اطلاع نویسندگان مقاله، موضوع به کارگیری تلفیق CGSA و BGSA در انتخاب ورودی‌ها و آموزش شبکه عصبی با هدف پیش‌بینی میزان غلظت آلاینده‌ها، تاکنون در مرجعی گزارش نشده است.

### ۳. داده‌های ورودی به مدل پیش‌بین

برای پیش‌بینی مقدار پارامترهای کیفی هوا، مجموعه‌ای از داده‌ها به عنوان ورودی به شبکه عصبی داده می‌شود که نمونه‌هایی از آن‌ها عبارت است از [۲۵]:

- الف. روزهای هفته (برای مثال، کاهش تردد خودروها در آخر هفته در اطراف مکان‌های اداری)؛
- ب. روزهای ماه (برای مثال، افزایش حجم ترافیک در مهرماه به علت بازگشایی مدارس)؛
- پ. سال اندازه‌گیری پارامترهای آلودگی هوا (برای مثال به دلیل آغاز فعالیت یک کارخانه در یک سال نسبت به سال قبل، آلودگی روند رو به رشدی دارد)،

6. Error Back-Propagation  
7. Support Vector Regression  
8. Takagi-Sugeno  
9. Identification  
10. Chaotic

1. Binary Gravitational Search Algorithm  
2. Knowledge Discovery  
3. Principal Component Analysis  
4. Support Vector Machine  
5. Chaotic Gravitational Search Algorithm

ر. فشار هوا (فشار هوا نیرویی است که در هر نقطه بر حسب وزن ستونی از هوا که در بالای آن نقطه وجود دارد، بر سطح وارد می‌شود. این فشار در سطح آب‌ها و دریاهای آزاد در حدود یک کیلوگرم بر سانتی‌متر مربع است. با افزایش ارتفاع از سطح زمین، به دلیل کاسته شدن ارتفاع ستون هوای قرار گرفته در بالای سطح، فشار هوا کاهش می‌یابد)؛

ز. میزان بارندگی؛

ژ. میزان تبخیر؛

س. غبار (ریزگرد به پدیده‌ای هواشناختی گفته می‌شود که در اثر گرد و غبار، ذرات خشک معلق و دود به وجود می‌آید). در این پژوهش، از داده‌های آلودگی هوا، مربوط به ایستگاه مهرآباد شهر تهران، برای یک دوره دوساله (سال‌های ۲۰۱۱ و ۲۰۱۲) استفاده شده است. داده‌های خام از سازمان هواشناسی ایران تهیه شده و دارای ۷۳۰ رکورد است.

### ۱.۳.۱. پیش‌پردازش داده‌ها

داده‌های موجود در جدول سازمان هواشناسی، بدین ترتیب برای استفاده در شبکه عصبی، پردازش شدند: ابتدا داده‌های نامعتبر پاک‌سازی شدند، سپس عمل هنجارسازی داده‌ها<sup>۴</sup> انجام شده و در نهایت با استفاده از BGSA ویژگی‌ها انتخاب شدند.

#### ۱.۳.۱.۱. پاک‌سازی داده‌ها

در برخی روزها، داده‌های هواشناسی و آلودگی هوا ثبت نشده است. این اتفاق می‌تواند به علت وجود اشکال در دستگاه ثبت اطلاعات باشد. برای تخمین و تکمیل اطلاعات آلودگی، پاک‌سازی داده‌ها چنین انجام شد: ابتدا کنترل داده‌های مشکوک و مقایسه آن با داده‌های روزهای قبل و بعد انجام شد. سپس داده‌های هواشناسی با مقدار معمول مقایسه شد. مثلاً در برخی روزها سرعت باد محاسبه شده از مقدار معقول سرعت باد در تهران، بسیار بیشتر است، که به هیچ‌وجه قابل قبول نیست.

از آنجاکه هدف از این پژوهش، تحقق شبکه عصبی مصنوعی برای پیش‌بینی میزان آلاینده ازن ( $O_3$ ) است، ستون‌های مربوط به آلاینده‌های  $CO$ ،  $PM_{10}$ ،  $NO_2$  و  $SO_2$  حذف شدند.

ت. سرعت باد (وزش باد در پراکندگی آلودگی هوا تأثیر محسوسی دارد و با افزایش ارتفاع، سرعت باد روند افزایشی دارد)؛

ث. جهت باد (جهت باد را از سمتی که می‌وزد گزارش می‌کنند، مثلاً باد شمال از شمال به جنوب می‌وزد. جهت باد معمولاً یا با چهار جهت اصلی و یا با درجه سمت<sup>۱</sup> گزارش می‌شود. برای مثال، بادی که از جنوب می‌وزد، باد ۱۸۰ درجه و بادی که از شرق می‌وزد، باد ۹۰ درجه نامیده می‌شود)؛

ج. باد غالب (هر منطقه باد غالب و برجسته‌ای دارد که در فصل خاص و گاهی در تمام فصول می‌وزد. باد غالب، باد خاصی است که وزش آن طولانی‌تر بوده و در جهت خاصی می‌وزد)؛

چ. رطوبت نسبی (به میزان بخارآب موجود در جو، رطوبت می‌گویند. نسبت بخارآب موجود در حجم معینی از هوا در دمای  $t$  به وزن بیشینه بخارآبی را که می‌تواند در همین حجم در دمای  $t$  داشته باشد، رطوبت نسبی می‌گویند)؛

ح. قابلیت دید<sup>۲</sup> (قابلیت دید در هوا، بزرگ‌ترین فاصله‌ای است که امکان دیدن و تشخیص دادن با چشم غیر مسلح وجود دارد. دید در هواشناسی اندازه فاصله‌ای است که در آن یک شیء یا نور می‌تواند تشخیص داده شود)؛

خ. فشار سطح دریا<sup>۳</sup> (فشار اتمسفری، فشار جو یا فشار هوا، مقدار نیرویی است که از طرف جو به واحد سطح اعمال می‌شود. با افزایش ارتفاع از سطح زمین فشار هوا کاهش می‌یابد. بنابراین مطابق قرارداد، برای استانداردسازی واحدها، از فشار معادل سطح دریا در گزارشات هواشناسی استفاده می‌شود)؛

د. دما (بزرگ‌ترین تأثیری که پارامتر دما بر آلودگی هوا دارد، ایجاد اختلاف فشار در مناطق مختلف و در نتیجه ایجاد حرکت در هوا و جابه‌جایی و پراکنش آلودگی است که می‌تواند با خود کاهش غلظت‌ها را به دنبال داشته باشد. عدم امکان وقوع این پدیده در ایجاد وارونگی دمایی نقش اصلی را دارد)؛

ذ. مقدار غلظت آلاینده در روز قبل؛

1. Azimuth
2. Visibility
3. Sea level pressure

4. Data normalization

است (ویژگی‌های ۱۶ و ۲۰)؛ لذا آن‌ها نیز به‌عنوان ورودی‌های مستقل در نظر گرفته شده‌اند.

جدول (۱): داده‌های ورودی مدل پیش‌بینی غلظت آلاینده  $O_3$  هوای

تهران

ردیف	نام داده	شرح
۱	Visibility_min	کمینه میزان دید
۲	Temperature_max	بیشینه دما
۳	Temperature_min	کمینه دما
۴	Temperature_avg	میانگین دما
۵	Sea level pressure_min	کمینه فشار سطح دریا
۶	Sea level pressure_avg	میانگین فشار سطح دریا
۷	Station level pressure_avg	میانگین فشار سطح ایستگاه
۸	Nebulosity	غبار
۹	Humidity_min	کمینه رطوبت
۱۰	Humidity_max	بیشینه رطوبت
۱۱	Humidity_avg	میانگین رطوبت
۱۲	Wind direction_03	جهت باد در ارتفاع ۳ متری
۱۳	Wind direction_09	جهت باد در ارتفاع ۹ متری
۱۴	Wind direction_15	جهت باد در ارتفاع ۱۵ متری
۱۵	Wind direction_avg	میانگین جهت باد
۱۶	Wind direction_max	بیشینه جهت باد
۱۷	Wind speed_03	سرعت باد در ارتفاع ۳ متری
۱۸	Wind speed_09	سرعت باد در ارتفاع ۹ متری
۱۹	Wind speed_15	سرعت باد در ارتفاع ۱۵ متری
۲۰	Wind speed_max	بیشینه سرعت باد

### ۳.۱.۲. هنجارسازی داده‌ها

هنجارسازی داده‌ها با به‌کارگیری رابطه (۱) انجام شده است:

$$X = 2 * \frac{x - \min(x)}{\max(x) - \min(x)} - 1 \quad (1)$$

که  $\min(x)$  مین کمینه و  $\max(x)$  مبین بیشینه بردار ورودی  $x$  بوده و  $X$  مقدار هنجارشده آن است.

### ۳.۲. انتخاب ویژگی

در این پژوهش، از الگوریتم جستجوی گرانشی دودویی برای

ستون‌های Rain24 (میانگین بارندگی در ۲۴ ساعت گذشته) و Evapor\_transpiration (میزان تبخیر) به‌علت دارا بودن تعداد بسیار زیاد نقص داده‌ها (به‌ترتیب ۴۷۸ و ۲۰۸) حذف شدند. در سایر ستون‌های جدول داده‌ها، نقص داده‌ها با میانگین سایر داده‌های موجود در همان ستون، جای‌گذاری شدند. در نهایت با اعمال موارد فوق، داده‌های ۶۸۱ روز قابل قبول شناخته شد که شامل ۲۰ ویژگی ورودی به‌صورت جدول (۱) و مقدار خروجی ازن هستند. بدین ترتیب برای پیش‌بینی میزان آلاینده ازن در هر روز، از داده‌های روز گذشته استفاده شده است. گستره مقدار غلظت ازن در دادگان موجود نیز در بازه ۲۵ تا ۹۷۸ جزء در هزار میلیون<sup>۱</sup> (ppb) است.

شایان یادآوری است که پارامترهای زیادی از جمله دما، رطوبت، و وزش باد فشار سطح دریا را تغییر می‌دهند؛ لذا فشار مطلق سطح دریا در طول روزهای مختلف، متفاوت بوده و در دادگان موجود بین ۹۸۸/۵ و ۱۰۳۲/۵ میلی‌بار گزارش شده است.

گفتنی است که انواع متفاوتی برای جهت باد در دادگان مورداستفاده در این مقاله بدین ترتیب در نظر گرفته شده است: شمال به جنوب، شمال به شرق، شمال به غرب، جنوب به شمال، جنوب به شرق، جنوب به غرب، شرق به شمال، شرق به جنوب، شرق به غرب، غرب به شمال، غرب به جنوب، و غرب به شرق. براین‌اساس، در داده‌های سازمان هواشناسی این جهت‌ها با اعداد صفر تا ۱۱ شماره‌گذاری شده‌اند. لذا جهت باد، یک داده مقیاس‌پذیر در نظر گرفته شده و حتی میانگین آن نیز با یک عدد غیرصحیح در دادگان گزارش شده و به‌عنوان ورودی به شبکه عصبی اعمال می‌شود.

مقدار ویژگی پانزدهم (میانگین جهت باد) در دادگان ارائه‌شده در رکوردهای مختلف، لزوماً میانگین ۳ مقدار متناظر در ویژگی‌های دوازدهم تا چهاردهم (جهت باد در ارتفاع‌های ۳، ۹ و ۱۵ متری) نیست که حکایت از اندازه‌گیری در ارتفاع‌های مختلف می‌کند؛ لذا به‌عنوان ویژگی مستقل در نظر گرفته شده است. این وضعیت درباره ویژگی‌های مبین بیشینه نیز برقرار

1. Parts per billion

جدول (۲): مقادیر در نظر گرفته شده برای پارامترهای BGSA

نام پارامتر	مقدار
اندازه جمعیت	۴۰
تعداد تکرارها	۳۰
ضریب ثابت گرانشی	۱

جدول (۳): ویژگی‌های انتخاب شده توسط BGSA

ردیف	نام ویژگی
۱	کمینه دما
۲	میانگین دما
۳	کمینه فشار سطح دریا
۴	بیشینه رطوبت
۵	میانگین رطوبت
۶	جهت باد در ارتفاع ۳ متری
۷	جهت باد در ارتفاع ۱۵ متری
۸	بیشینه جهت باد
۹	سرعت باد در ارتفاع ۳ متری
۱۰	سرعت باد در ارتفاع ۹ متری

حل مسئله انتخاب ویژگی استفاده شده است. نسخه دودویی الگوریتم جستجوی گرانشی توسط راشدی و همکاران در سال ۲۰۱۰ معرفی شده است [۲۶]. در مسئله انتخاب ویژگی با BGSA هر جرم می‌تواند یک جواب برای مسئله باشد. هر جواب یا جرم به صورت رشته‌ای از صفر و یک‌ها تعریف می‌شود. طول رشته برابر کل ویژگی‌هاست. مقدار صفر و یا یک برای هر رشته - بیت به ترتیب بیانگر مشارکت و یا عدم مشارکت ویژگی متناظر با آن بیت است. پس از ایجاد جمعیت اولیه اجرام، برای هر جرم مقدار برازندگی آن با استفاده از تابع برازندگی که در اینجا میانگین مربعات خطا (MSE) است، محاسبه می‌شود. در هر مرحله، بهترین جرم (که با توجه به هدف مسئله مشخص می‌شود) انتخاب می‌شود. به تعداد تکرارهای مسئله، الگوریتم اجرا می‌شود و در نهایت با انتخاب جرم با کمترین مقدار تابع برازندگی ویژگی‌های مناسب به دست می‌آیند [۲۷].

تابع احتمال  $S(V_i^d)$  طبق رابطه (۲) تعریف می‌شود [۲۶]:

$$S(V_i^d(t)) = |\tanh(V_i^d(t))| \quad (2)$$

که در آن،  $\tanh$  مبین تابع تانژانت هیپربولیک است. پس از محاسبه  $S(V_i^d)$  اجرام طبق رابطه (۳) جابه‌جا می‌شوند:

if rand <  $S(V_i^d(t+1))$  then

$$x_i^d(t+1) = \text{complement}(x_i^d(t)) \text{ else } \quad (3)$$

که در آن، rand یک متغیر تصادفی یکنواخت در بازه  $[0,1]$  و complement مبین عملگر متمم منطقی (نفی) است. مقادیر در نظر گرفته شده برای پارامترهای CGSA به شرح جدول (۲) می‌باشد. بهترین جواب به دست آمده برای MSE مقدار  $0.0022$  بود. خروجی اجرای CGSA بر روی داده‌های سازمان هواشناسی، ۱۰ ویژگی برای پیش‌بینی آلاینده‌های هوای شهر تهران به صورت جدول (۳) بود که این ویژگی‌ها به عنوان ورودی به شبکه عصبی داده شدند.

#### ۴. بررسی کارایی روش‌های بهینه‌سازی در آموزش

##### MLP

پس از آماده‌سازی داده‌ها، شبکه عصبی باید با استفاده از داده‌های ایستگاه مهرآباد شهر تهران آموزش ببیند تا بتواند با توجه به قابلیت تعمیم ذاتی خود، برای سایر نقاط تهران آلودگی را پیش‌بینی کند.

شبکه پیشنهادی مورد نظر یک شبکه MLP با یک لایه مخفی و تعداد ۴ نرون در لایه مخفی است. تابع تحریک مورد استفاده در این شبکه برای لایه پنهان، سیگموئید (Tansig) و برای لایه خروجی، خطی (Purelin) انتخاب شد. از بین ۶۸۱ رکورد موجود در جدول داده‌ها، ۷۰ درصد داده‌ها (۴۷۷ رکورد) به صورت تصادفی، برای آموزش و اعتبارسنجی<sup>۲</sup> شبکه (به ترتیب با ابعاد ۵۰ و ۲۰ درصد داده‌ها) و ۳۰ درصد باقی مانده (۲۰۴ رکورد)، برای آزمون آن به کار گرفته شد.

در شرایط یکسان، شبکه عصبی MLP مورد نظر برای پیش‌بینی غلظت آلاینده  $O_3$  هوای شهر تهران توسط الگوریتم‌های

##### 1. Mean Square Error

##### 2. Validation

گام‌های اصلی این الگوریتم چنین هستند [۲۹]:

۱. منابع غذای اولیه برای تمامی زنبورهای کارگر تأمین می‌شود.
۲. هر زنبور کارگر براساس حافظه خود به سراغ یک منبع غذا می‌رود و منبع همسایه را مشخص می‌کند. سپس میزان شهد آن را مشخص می‌کند و در کندو به حرکت درمی‌آید.
۳. هر زنبور ناظر حرکت زنبورهای کارگر را مشاهده کرده و براساس آن یکی از منابع آن‌ها را انتخاب می‌کند و سپس به سمت آن منبع می‌رود. پس از انتخاب یک همسایه اطراف آن، میزان شهد آن را ارزیابی می‌کند.
۴. منابع غذای متروکه تعیین و با منابع غذای جدید که توسط زنبورهای پیشاهنگ کشف شده‌اند، جایگزین می‌شوند.
۵. بهترین منبع غذای یافت‌شده ثبت می‌شود.
۶. بازگشت به گام دوم و تکرار الگوریتم تا برآورده شدن شرایط توقف.

در این پژوهش، الگوریتم ABC برای آموزش شبکه MLP مورد استفاده قرار گرفت که جمعیت اولیه آن برابر ۴۰ و پس از ۱۰۰ بار تکرار الگوریتم، بهترین جواب به دست آمده برای MSE مقدار ۰/۰۰۲۳ بود.

#### ۳.۴ آموزش MLP با الگوریتم GA+SA

در این پژوهش، الگوریتم وراثتی (GA) و شبیه‌سازی تبرید (SA)، برای آموزش شبکه عصبی MLP با یکدیگر ترکیب شده‌اند. در الگوریتم وراثتی، هر کروموزوم نشان‌دهنده یک نقطه در فضای جستجو و یک راه‌حل ممکن برای مسئله مورد نظر است. کروموزوم‌ها (راه‌حل‌ها) از تعداد ثابتی ژن (متغیر) تشکیل شده‌اند. برای نمایش کروموزوم‌ها معمولاً از کدگذاری‌های دودویی استفاده می‌شود. مجموعه‌ای از کروموزوم‌ها یک جمعیت را تشکیل می‌دهند. با تأثیر عملگرهای وراثتی بر روی هر جمعیت، جمعیت جدیدی با همان تعداد کروموزوم تشکیل می‌شود [۳۰].

بسیاری از الگوریتم‌های بهینه‌سازی با الگوگیری و شبیه‌سازی یکی از قوانین یا روابط موجود در طبیعت بنا نهاده می‌شوند. الگوریتم شبیه‌سازی تبرید نیز بر مبنای فرایند تبرید یا بازپخت فلزات بنا نهاده شده است [۳۱]. فرایندی که ذکر شد بدین صورت

EBP، اجتماع زنبورها (ABC)، ترکیب GA<sup>۲</sup> و SA<sup>۳</sup>، PSO<sup>۴</sup>، GSA<sup>۵</sup> و CGSA آموزش داده شد. تمام نتایج برای ۱۰۰ بار تکرار هر الگوریتم آورده شده است. همچنین با توجه به تصادفی بودن الگوریتم‌های فوق، تمام آزمایش‌ها ۱۰ مرتبه تکرار شده است.

#### ۱.۴ آموزش MLP با الگوریتم پس‌انتشار خطا

در الگوریتم EBP در هر مرحله، مقدار خروجی محاسبه شده جدید با مقدار واقعی، مقایسه شده و با توجه به خطای به دست آمده به اصلاح وزن‌های شبکه پرداخته می‌شود، به نحوی که در انتهای هر تکرار، اندازه خطای حاصل کمتر از میزان به دست آمده در تکرار قبلی باشد. الگوریتم EBP را می‌توان متشکل از چهار گام اصلی در نظر گرفت [۲۸]. بدین ترتیب که پس از انتخاب تصادفی ضرایب وزن شبکه، گام‌های زیر طی می‌شود:

۱. محاسبات سطح فعالیت و خروجی نرون‌ها در مسیر ورودی به خروجی؛
  ۲. پس‌انتشار به لایه خروجی و تغییر ضرایب وزن لایه خروجی؛
  ۳. پس‌انتشار به لایه (های) مخفی و تغییر ضرایب وزن لایه (های) مخفی؛
  ۴. تکرار الگوریتم تا هنگامی که به آستانه خطای مورد پذیرش رسیده یا تعداد تکرارهای تعیین شده انجام شده باشد.
- در این پژوهش، الگوریتم EBP نیز برای آموزش شبکه MLP مورد استفاده قرار گرفت. بهترین جواب به دست آمده برای MSE مقدار ۰/۰۰۵۵ بود.

#### ۲.۴ آموزش MLP با الگوریتم اجتماع زنبورها

در الگوریتم ABC موقعیت منبع غذایی یک راه‌حل مسئله بهینه‌سازی را نشان می‌دهد. یادآوری می‌شود که در الگوریتم ABC سه گروه زنبور وجود دارد: کارگر<sup>۶</sup>، ناظر<sup>۷</sup> و پیشاهنگ<sup>۸</sup>.

1. Artificial Bee Colony
2. Genetic Algorithm
3. Simulated Annealing
4. Particle Swarm Optimization
5. Gravitational Search Algorithm
6. Employed
7. Onlooker
8. Scout

گروه پرندگان مدل‌سازی شده است. این الگوریتم از حرکت دسته‌جمعی پرندگانی که به دنبال غذا هستند، الهام گرفته شده است. گروهی از پرندگان در فضایی به صورت تصادفی به دنبال غذا می‌گردند. هیچ‌یک از پرندگان محل غذا را نمی‌دانند. یکی از بهترین تدابیر می‌تواند دنبال کردن پرنده‌ای باشد که کمترین فاصله را تا غذا داشته باشد. این تدبیر در واقع جان‌مایه الگوریتم است. فضای مورد جستجو در الگوریتم PSO معادل فضای مورد جستجو در الگوی حرکت پرندگان است. هر راه‌حل در الگوریتم PSO، که به آن یک ذره گفته می‌شود، معادل یک پرنده است و تعداد ذرات (راه‌حل‌ها) معادل تعداد پرندگان است. هر ذره یک مقدار شایستگی دارد که توسط یک تابع برازش محاسبه می‌شود و هرچه ذره در فضای جستجو به هدف (یعنی غذا در مدل حرکت پرندگان) نزدیک‌تر باشد، برازش بیشتری دارد. همچنین هر ذره دارای یک جابه‌جایی است که هدایت حرکت ذره را بر عهده دارد و به کمک آن، مکان بعدی ذره مشخص می‌شود. هر ذره با دنبال کردن ذرات بهینه در حالت فعلی، به حرکت خود در فضای جستجو ادامه می‌دهد تا اینکه در نهایت به جواب بهینه دست یابد.

الگوریتم PSO از چهار گام اصلی به ترتیب زیر تشکیل شده است [۳۳]:

۱. ارزیابی برازش هر ذره؛
  ۲. به‌روزرسانی برازش‌های تکی و جمعی؛
  ۳. به‌روزرسانی سرعت و مکان هر ذره؛
  ۴. تکرار الگوریتم تا هنگامی که شرایط توقف برآورده شود.
- در این پژوهش، الگوریتم PSO برای آموزش شبکه MLP مورد استفاده قرار گرفت که جمعیت اولیه در آن برابر ۴۰ و پس از ۱۰۰ بار تکرار الگوریتم، بهترین جواب به‌دست‌آمده برای MSE مقدار ۰/۰۰۳۶ بود.

#### ۵.۴ آموزش MLP با الگوریتم GSA

در سال ۲۰۰۹، روش بهینه‌سازی دیگری به نام الگوریتم جستجوی گرانشی توسط راشدی و همکاران معرفی شد [۳۴]. این الگوریتم، از خانواده الگوریتم‌های هوش جمعی است که از

است که مواد تا حد امکان گرم شده و به آهستگی سرد می‌شوند تا به کمترین حد انرژی خود برسند و به اصطلاح، به پایداری ترمودینامیکی برسند. الگوریتم شبیه‌سازی تبرید الگوریتمی مبتنی بر جمعیت نیست و براساس یک نقطه عمل می‌کند. این الگوریتم براساس جستجوی محلی عمل کرده و عملکرد خوبی در مسائل گسسته و پیوسته دارد [۳۱]. برای حل یک مسئله بهینه‌سازی، الگوریتم SA ابتدا از یک جواب اولیه شروع می‌کند و سپس در یک حلقه تکرار به جواب‌های همسایه حرکت می‌کند. اگر جواب همسایه بهتر از جواب فعلی باشد، الگوریتم آن را به‌عنوان جواب فعلی قرار می‌دهد (به آن حرکت می‌کند)، در غیر این صورت، الگوریتم آن جواب را با احتمال  $\exp(-\Delta E/T)$  به‌عنوان جواب فعلی می‌پذیرد. در این رابطه،  $\Delta E$  تفاوت بین تابع هدف جواب فعلی و جواب همسایه است و  $T$  یک پارامتر به نام دماست. در هر دما، چندین تکرار اجرا و سپس دما به آرامی کاهش داده می‌شود. در گام‌های اولیه دما خیلی بالا قرار داده می‌شود تا احتمال بیشتری برای پذیرش جواب‌های بدتر وجود داشته باشد. با کاهش تدریجی دما، در گام‌های پایانی احتمال کمتری برای پذیرش جواب‌های بدتر وجود خواهد داشت و بنابراین الگوریتم به سمت یک جواب خوب همگرا می‌شود [۳۲].

روال کار در این روش ترکیبی نیز به این صورت بوده که ابتدا توسط الگوریتم وراثتی، عملگرهای تقاطع و جهش انجام پذیرفته است. سپس برای تشکیل جمعیت جدید، از الگوریتم شبیه‌سازی تبرید استفاده شده است. بدین صورت که ابتدا جمعیت فرزندان و جمعیت جهش‌یافتگان با یکدیگر ترکیب شده و برحسب تابع هدف (در اینجا MSE) به تعداد جمعیت (در اینجا ۴۰) از آن‌ها را جدا می‌کنیم. این جمعیت ۴۰ عضوی را با استفاده از قانون SA با جمعیت قبلی مقایسه و جایگزین می‌کنیم. جمعیت اولیه در این الگوریتم برابر ۴۰ و پس از ۱۰۰ بار تکرار، بهترین جواب به‌دست‌آمده برای MSE مقدار ۰/۰۰۳۷ بود.

#### ۴.۴ آموزش MLP با الگوریتم PSO

الگوریتم بهینه‌سازی ازدحام ذرات یک الگوریتم بهینه‌سازی تصادفی براساس جمعیت است که از شبیه‌سازی رفتار اجتماعی

$$R_{ij}(t) = \|X_i(t), X_j(t)\|^2 \quad (۶)$$

در رابطه (۵)،  $\varepsilon$  یک عدد بسیار کوچک است. نیروی وارد بر جرم  $i$  در جهت بُعد  $d$  در زمان  $t$  ( $F_i^d(t)$ )، برابر مجموع نیروهایی است که  $k$  جرم برتر جمعیت بر جرم وارد می‌کنند (رابطه ۷). مقصود از اجرام برتر، عامل‌هایی هستند که دارای برازندگی بیشتری باشند.

$$F_i^d(t) = \sum_{j \in kbest, j \neq i} rand_j(t) \times F_{ij}^d(t) \quad (۷)$$

در رابطه (۷)،  $kbest$  بیانگر مجموعه  $k$  جرم برتر جمعیت است که بهترین مقدار برازندگی و بیشترین جرم را دارند. همچنین در این رابطه،  $rand_j$  عددی تصادفی با توزیع یکنواخت در بازه  $[0,1]$  است که برای حفظ خصوصیت تصادفی بودن جستجو در نظر گرفته می‌شود.

طبق قانون دوم نیوتن هر جرم در جهت بُعد  $d$  شتابی می‌گیرد که متناسب است با نیروی وارد بر جرم  $i$  در آن جهت، تقسیم بر جرم  $i$ . رابطه (۸) شتاب جرم  $i$  در جهت بُعد  $d$  در زمان  $t$  را با  $a_i^d(t)$  نشان می‌دهد.

$$a_i^d(t) = F_i^d(t)/M_i(t) \quad (۸)$$

سرعت هر جرم برابر مجموع ضربی از سرعت فعلی جرم و شتاب جرم است که طبق رابطه (۹) تعریف می‌شود. موقعیت جدید بُعد  $d$  از جرم  $i$  نیز به صورت رابطه (۱۰) محاسبه می‌شود.

$$V_i^d(t+1) = rand_i \times V_i^d(t) + a_i^d(t) \quad (۹)$$

$$x_i^d(t+1) = x_i^d(t) + V_i^d(t+1) \quad (۱۰)$$

در روابط فوق،  $V_i^d(t)$  سرعت بُعد  $d$ م عامل  $i$  در زمان  $t$  و  $rand_i$  عددی تصادفی با توزیع یکنواخت در بازه  $[0,1]$  است. برای تنظیم ضریب گرانش از رابطه (۱۱) استفاده می‌شود.

$$G(t) = G_0 [\exp(-at/T)] \quad (۱۱)$$

که در آن،  $G_0$  مقدار اولیه ثابت گرانش است؛  $t$  تکرار جاری و  $T$  تعداد کل تکرارهاست. ثابت گرانش، پارامتری مناسب برای کنترل دو ویژگی کاوش و بهره‌وری در این الگوریتم به‌شمار می‌آید. مقادیر بزرگ آن موجب تقویت توانایی کاوش الگوریتم و مقادیر کوچک آن موجب افزایش توانایی بهره‌وری الگوریتم می‌شود. از آنجاکه در مراحل اولیه جستجو لازم است الگوریتم به جستجوی نقاط جدیدی در فضای مسئله پرداخته شود و در

قوانین جاذبه میان اجرام و حرکت نیوتنی الهام گرفته شده است. طبق قانون جاذبه نیوتن، هر جسم به اجسام دیگر نیرو وارد کرده و آن‌ها را به سمت خود جذب می‌کند. به‌وضوح، هرچه این اجسام بزرگ‌تر و نزدیک‌تر باشند، تأثیر این نیرو بیشتر خواهد بود. در نتیجه هر جسم با استفاده از نیروی جاذبه، محل و مقدار جرم سایر اجسام را درک می‌کند. بنابراین می‌توان از این نیرو به‌عنوان رسانه‌ای برای تبادل اطلاعات استفاده کرد. از الگوریتم جستجوی گرانشی در حل مسائل بهینه‌سازی استفاده می‌شود. در این الگوریتم، پاسخ‌های موردنظر، موقعیت اجرام در فضای مسئله‌اند. میزان اجرام نیز باتوجه به تابع هدف تعیین می‌شود [۳۵].

پس از تشکیل سیستم، قوانین حاکم بر آن مشخص می‌شوند. فرض می‌کنیم تنها قانون گرانش و قوانین حرکت حاکم هستند. صورت کلی این قوانین تقریباً شبیه قوانین طبیعت است و به‌صورت زیر تعریف شده‌اند [۳۶]:

**قانون گرانش:** هر جرم در سیستم مصنوعی، تمام اجرام دیگر را به سمت خود جذب می‌کند. مقدار این نیرو متناسب است با جرم گرانشی و عکس فاصله دو جرم.

**قانون حرکت:** سرعت فعلی هر جرم برابر است با مجموع ضربی از سرعت قبلی جرم و تغییر سرعت آن. تغییر سرعت یا شتاب هر جرم نیز برابر است با نیروی وارد بر آن تقسیم بر جرم اینرسی.


سیستم به‌صورت مجموعه‌ای از  $m$  جرم تصور می‌شود. موقعیت هر جرم می‌تواند جوابی برای مسئله باشد. در رابطه (۴) موقعیت بُعد  $d$  از جرم  $i$  با  $x_i^d$  نشان داده می‌شود:

$$x_i = (x_i^1, \dots, x_i^d, \dots, x_i^n), \quad i = 1, 2, \dots, m \quad (۴)$$

$n$  در رابطه (۴) نشان‌دهنده بُعد فضای پاسخ است. در این سیستم در زمان  $t$ ، به هر جرم  $i$  از سوی جرم  $j$  در جهت بُعد  $d$  نیرویی به اندازه  $F_{ij}^d(t)$  وارد می‌شود. مقدار این نیرو طبق رابطه (۵) محاسبه می‌شود.  $G(t)$  ثابت گرانش در زمان  $t$  و  $R_{ij}$  فاصله بین دو جرم  $i$  و  $j$  است. برای تعیین فاصله بین اجرام مطابق رابطه (۶) از فاصله اقلیدسی استفاده می‌شود.

$$F_{ij}^d(t) = G(t) \frac{M_i(t) \cdot M_j(t)}{R_{ij}(t) + \varepsilon} (x_j^d(t) - x_i^d(t)) \quad (۵)$$

استفاده شده است. از این رو با توجه به زمینه‌های کاربردی مورداستفاده، نسخه‌های متفاوتی از این الگوریتم ارائه شده است که می‌توان به BGSA [۲۶]، الگوریتم جستجوی گرانشی نسخه‌گرای پیشرفته (AEGSA) [۴۱]، و الگوریتم جستجوی گرانشی چندهدفه (MOGSA) [۴۲] اشاره کرد.



شکل (۱): روندنمای الگوریتم GSA [۳۴]

الگوریتم جستجوی گرانشی باید به گونه‌ای هدایت شود که موقعیت اجرام با گذشت زمان بهبود پیدا کند. استراتژی به‌کارگرفته شده برای این منظور، مبنی بر تنظیم جرم عامل‌هاست. طبق روابط ارائه شده، تمام عامل‌ها متناسب با جرمشان روی هم تأثیر می‌گذارند و اثرگذاری آن‌ها روی عامل‌های همسایه بیشتر است. تأثیر عامل‌های با جرم سنگین‌تر بیشتر است و شعاع تأثیرگذاری بزرگ‌تری دارند. بنابراین، به اجرامی که تابع برازش

مراحل پایانی با افزایش توان بهره‌وری به بهبود جواب‌های دیده‌شده بپردازد، گزینه مناسب برای ثابت گرانشی بایستی با یک مقدار اولیه بزرگ شروع شده و با گذشت زمان، مقدار آن به تدریج کاهش یابد.

در رابطه (۱۲)، جرم عامل‌ها بر مبنای تابع هدف آن‌ها تنظیم می‌شود. به گونه‌ای که به عامل‌های با برازش بیشتر، جرم بیشتری نسبت داده می‌شود.

$$m_i(t) = [fit_i(t) - worst(t)] / [best(t) - worst(t)] \quad (12)$$

در این رابطه،  $fit_i(t)$  بیانگر میزان برازندگی جرم  $i$  در زمان  $t$  است،  $best(t)$  و  $worst(t)$  به ترتیب بیانگر میزان برازش بهترین و بدترین عامل جمعیت در زمان  $t$  هستند. در نهایت، اندازه جرم عامل‌ها طبق رابطه (۱۳) هنجار می‌شود.

$$M_i(t) = m_i(t) / \sum_{j=1}^N m_j(t) \quad (13)$$

از آنجاکه در این پژوهش، هدف کاهش میزان MSE می‌باشد، این مسئله یک مسئله کمینه‌یابی بوده و می‌توان از روابط (۱۴) و (۱۵) برای محاسبه بهترین و بدترین عامل‌ها استفاده کرد.


$$best(t) = \min_{j \in [1, \dots, m]} fit_j(t) \quad (14)$$

$$worst(t) = \max_{j \in [1, \dots, m]} fit_j(t) \quad (15)$$


در ابتدای تشکیل سیستم، هر جسم به صورت تصادفی در یک نقطه از فضا قرار می‌گیرد که جوابی از مسئله است. در هر لحظه از زمان، اجرام ارزیابی شده، سپس تغییر مکان هر جرم پس از محاسبه روابط (۴) تا (۱۵) محاسبه می‌شود. پارامترهای سیستم نیز در هر مرحله به‌روزرسانی می‌شوند. شرط توقف، رسیدن به حداکثر تعداد تکرار است. در شکل (۱) روندنمای GSA نشان داده شده است.

ویژگی‌های مثبت GSA همچون همگرایی سریع، عدم توقف در بهینه‌های محلی، کاهش حجم محاسباتی نسبت به الگوریتم‌های تکاملی و عدم نیاز به حافظه در مقایسه با دیگر الگوریتم‌های خانواده هوش جمعی، بستر جدیدی از تحقیقات را فراروی محققان قرار داده است. این الگوریتم تا به حال در کاربردهای متنوعی همچون طراحی فیلتر [۳۷]، انتخاب ویژگی [۳۸]، جبران‌سازی توان راکتو [۳۹] و آموزش شبکه عصبی [۴۰]

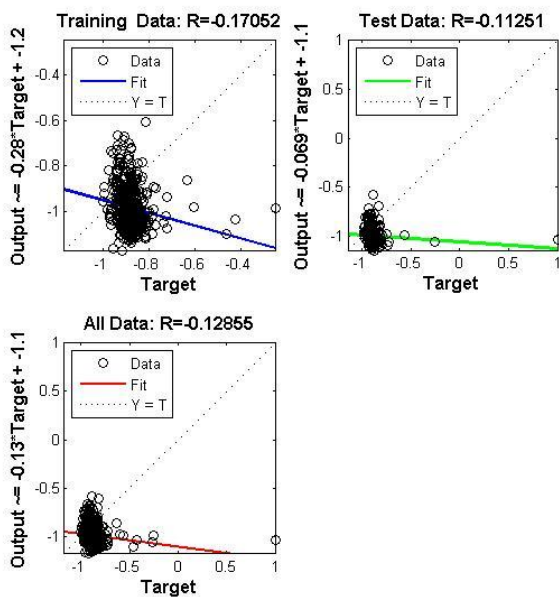




شکل (۲): میزان MSE در تکرارهای GSA



شکل (۳): میزان خطا در GSA



شکل (۴): تقابل میان خروجی شبکه و خروجی موردانتظار در GSA

بهتری دارند، جرم گرانشی بهتری نسبت داده می‌شود. در نتیجه هر جرم به اندازهٔ برآزش خود، سایر اجرام را به سمت خود جذب می‌کند. بنابراین با گذشت زمان، اجرام به سمت موقعیت‌های مناسب‌تر می‌روند [۳۵]. تغییر موقعیت یک جرم به معنای به‌روزرسانی وزن‌های شبکه در جهت کاهش MSE در تکرار جاری است.

در هر تکرار، تمام اجرام موقعیتشان را با محاسبهٔ سرعت جدید به‌روزرسانی و به سمت موقعیت جدید حرکت می‌کنند [۴۳]. از آنجاکه این الگوریتم حافظه‌دار نیست، هیچ‌یک از موقعیت‌های دیده‌شدهٔ قبلی را به‌خاطر نمی‌سپارد. با وجود این دیده می‌شود که عملکردی به‌خوبی الگوریتم‌های حافظه‌دار دارد [۳۵]. اما الگوریتم جستجوی گرانشی، پیچیدگی محاسباتی بالاتری نسبت به الگوریتم‌هایی مانند PSO داشته و از سوی دیگر پیچیدگی محاسباتی آن نسبت به الگوریتم وراثتی پایین‌تر است [۳۵]. یک راه برای ایجاد مصالحه بین بهره‌وری و کاوش، کاهش تعداد عامل‌ها با گذر زمان است. از این‌رو پیشنهاد می‌شود که مجموعه‌ای از عامل‌ها با جرم سنگین‌تر نیروی‌شان را بر دیگران وارد آورند. به‌رحال باید مراقب این راهکار باشیم؛ چراکه ممکن است کاوش را کاهش و بهره‌وری را افزایش دهد [۳۴].

برای جلوگیری از افتادن در نقاط بهینهٔ محلی، الگوریتم باید کاوش را در ابتدا در نظر بگیرد و با ادامهٔ تکرارها، بهره‌وری باید ظاهر شده و کاوش کم‌رنگ شود. برای افزایش کارایی GSA با کنترل کاوش و بهره‌وری، تنها تعداد  $k_{best}$  عامل، عوامل دیگر را جذب خواهند کرد.  $k_{best}$  تابعی از زمان است که مقدار اولیهٔ آن  $K_0$  بوده و در گذر زمان کاهش می‌یابد. به‌عبارتی، در ابتدا تمام عوامل نیروی خود را به عوامل دیگر وارد می‌کنند و با گذر زمان  $k_{best}$  به‌صورت خطی کاهش یافته و در انتها، تنها یک عامل خواهد بود که به دیگران نیرو وارد می‌کند [۳۴].

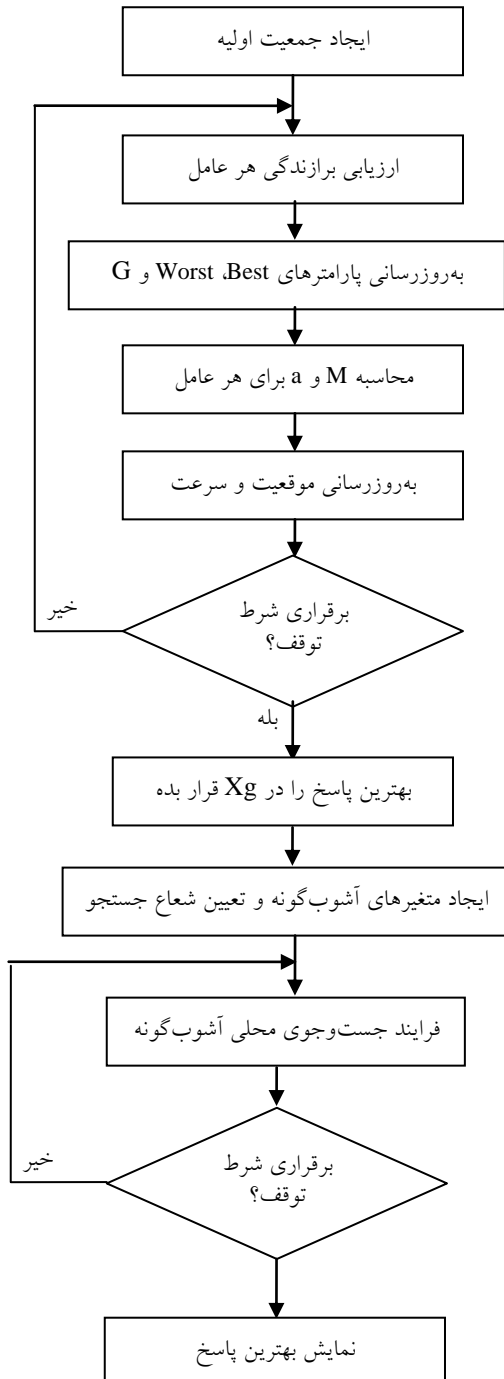
در این پژوهش، GSA برای آموزش شبکهٔ MLP مورد استفاده قرار گرفت که جمعیت اولیهٔ در آن برابر ۴۰ و پس از ۱۰۰ بار تکرار الگوریتم، بهترین جواب به‌دست‌آمده برای MSE مقدار ۰/۰۰۱۹ بود. نتایج خروجی این الگوریتم در شکل‌های (۲) تا (۴) نمایش داده شده است.

## ۶.۴ آموزش MLP با CGSA

- گام دوم: متغیرهای آشوب‌گونه برای تکرار بعدی طبق

رابطه (۲۰) تعیین می‌شوند:

$$Cx^{(k+1)} = \sin[a/Cx^{(k)}] \quad (20)$$



شکل (۵): روندنمای CGSA [۲۴]

از سال ۲۰۰۹ تاکنون، نسخه‌های متعددی از GSA معرفی شده است. CGSA در سال ۲۰۱۲ معرفی شد که در آن برای افزایش کارایی GSA، سازوکار آشوب به آن افزوده می‌شود که عبارت است از یک جستجوی محلی در اطراف جواب بهینه یافته‌شده توسط GSA [۲۴].

ایده اصلی جستجوی محلی آشوب‌گونه، استفاده از متغیرهای آشوب‌گونه است. تصادفی بودن متغیرهای آشوب‌گونه باعث می‌شود بهینه‌سازی آشوب‌گونه، نقاط بهینه سراسری را به سرعت بیابد [۲۴]. برای بهبود کارایی GSA در زمینه سرعت هم‌گرایی، جستجوی محلی آشوب‌گونه بر روی عامل بهینه یافته‌شده توسط GSA صورت می‌گیرد. به عبارتی پس از آنکه GSA، جواب بهینه  $(X_g)$  را یافت، از آنجاکه احتمال وجود جوابی بهتر از  $X_g$  در اطراف  $X_g$  بالا می‌باشد، جستجوی محلی آشوب‌گونه، به جستجوی اطراف  $X_g$  برای یافتن جوابی بهتر می‌پردازد. روندنمای CGSA در شکل (۵) نمایش داده شده است [۲۴]. روال جستجوی محلی آشوب‌گونه چنین است:

ابتدا متغیرهای آشوب‌گونه ساخته می‌شوند و سپس توسط آن‌ها عمل جستجوی محلی آغاز می‌شود. شعاع جستجو ( $\sigma$ ) محدوده جستجوی محلی را تعیین می‌کند و در هر تکرار نسبت به تکرار قبلی کاهش می‌یابد. در CGSA، فرایند جستجوی محلی آشوب‌گونه در اطراف جواب بهینه یافته‌شده توسط فرایند GSA برای یافتن جوابی بهتر از آن صورت می‌پذیرد.

- گام اول: فرض می‌شود که  $k=0$  و متغیرهای آشوب‌گونه به صورت تصادفی تعیین می‌شوند. سپس شعاع جستجو ( $\sigma$ ) به صورت دلخواه و محدوده جستجوی ( $X_{min_i}$  و  $X_{max_i}$ )  $X_{best}$  و  $F_{best}$  توسط روابط (۱۶) تا (۱۹) تعیین می‌شوند:


$$X_{max_i} = X_g + \sigma_i/2 \quad (16)$$

$$X_{min_i} = X_g - \sigma_i/2 \quad (17)$$

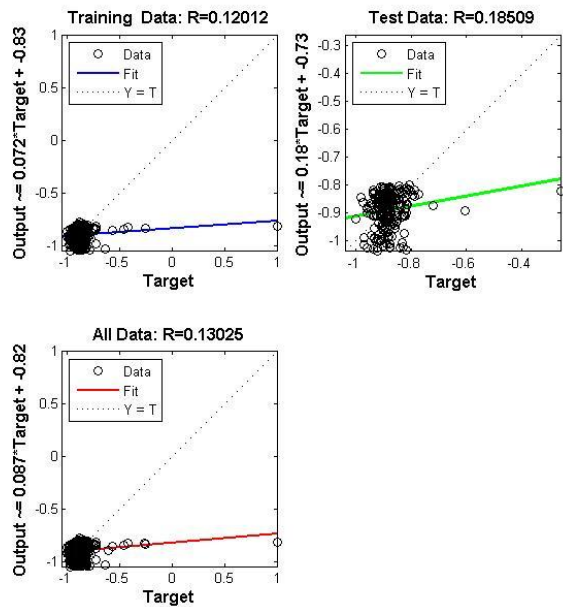
$$X_{best} = X_g \quad (18)$$

$$F_{best} = J_g \quad (19)$$

که در آن،  $J_g$  عبارت است از مقدار تابع برازندگی برای بهترین جواب یافته‌شده توسط GSA ( $X_g$ ).



شکل (۷): میزان خطا در CGSA



شکل (۸): تقابل میان خروجی شبکه و خروجی موردانتظار در CGSA

### ۵. نتیجه گیری

باتوجه به ماهیت غیرخطی آلودگی هوا و تأثیرپذیری از پارامترهای طبیعی مختلف، پیش‌بینی میزان آلاینده‌ها بسیار دشوار بوده و نیاز به استفاده از پارامترهای هواشناسی و مکانی مختلفی دارد. برای این منظور، روابط و روش‌های گوناگونی پیشنهاد شده‌اند که هرکدام در یک منطقه یا در شرایطی خاص، نتایج مطلوبی ارائه کرده‌اند. مدل‌های پیش‌بینی آلودگی هوا وسیله بسیار مؤثری است که به کمک آن، می‌توان برای مدیریت آلودگی هوای کلان‌شهرها، تدابیر مناسب و کم‌هزینه طرح‌ریزی کرد. لذا در این مقاله، سعی

- گام سوم: از رابطه (۲۱) برای به‌روزرسانی موقعیت اجرام استفاده می‌شود:

$$X_i^{(k+1)} = \frac{Xmax_i + Xmin_i}{2} + \frac{Xmax_i - Xmin_i}{2} Cx_i^k \quad (21)$$

- گام چهارم: موقعیت جدید اجرام، توسط تابع هدف (در این پژوهش، MSE) ارزیابی شده و در  $J_{k+1}$  نگهداری می‌شود.

- گام پنجم: اگر  $J_{k+1} < F_{best}$  در آن صورت  $X_{best} = X_{k+1}$  و  $F_{best} = J_{k+1}$


- گام ششم: شعاع جستجو طبق رابطه (۲۲) کاهش می‌یابد.

$$\sigma(k+1) = w \times \sigma(k) \quad (22)$$

که در آن،  $w$  یک عدد مثبت کوچک‌تر از یک است (برای مثال ۰/۹۸).

- گام هفتم: اگر تعداد تکرارهای مجاز به پایان نرسیده است، به گام دوم می‌رویم.

در این پژوهش، CGSA برای آموزش شبکه MLP مورد استفاده قرار گرفت که جمعیت اولیه در آن برابر ۴۰ و پس از ۱۰۰ بار تکرار الگوریتم، بهترین جواب به‌دست‌آمده برای MSE مقدار ۰/۰۰۱۷ بود که در مقایسه با GSA استاندارد، ۰/۰۰۰۲ بهبود داشت. نتایج خروجی این الگوریتم در شکل‌های (۶) تا (۸) نمایش داده شده است.




شکل (۶): میزان MSE در تکرارهای CGSA

انتخاب ویژگی‌های بهینه برای ورودی این سیستم پیش‌بین به‌کار گرفته شد. بدین ترتیب می‌توان با انتخاب گستره وسیعی از عوامل مؤثر در پیش‌بینی میزان غلظت آلاینده‌ها، به‌صورتی نظام‌مند و هوشمند عوامل مؤثرتر را انتخاب و با شبکه‌ای که از لحاظ ساختاری نیز حجیم و پیچیده نباشد، تخمین درست‌تری را ارائه کرد. برای نمونه، عملکرد مدل پیشنهادی در پیش‌بینی غلظت آلاینده  $O_3$  که مقایسه‌ای شهودی از مقادیر پیش‌بینی شده و خروجی‌های واقعی است، در شکل (۹) نشان داده شده است.


باتوجه به شکل (۹) عملکرد قابل قبول این مدل اثبات می‌شود. عملکرد پیش‌بینی‌کننده ارائه‌شده با پنج روش دیگر که در آن‌ها شبکه عصبی MLP با الگوریتم‌های پس‌انتشار خطا (EBP)، ABC، GA+SA، PSO و GSA استاندارد آموزش دیده بودند، مورد مقایسه قرار گرفت.

شد که با ارائه مدلی نوین برای پیش‌بینی میزان غلظت آلاینده‌های هوا، در این راستا گامی برداشته شود. شبکه‌های عصبی مصنوعی مدل‌های قدرتمندی برای پیش‌بینی آلاینده‌های هوا هستند. بسیاری از محققان تمایل دارند از این ابزار استفاده کنند، اما با مسئله آموزش شبکه عصبی مواجه می‌شوند. الگوریتم جست‌وجوی گرانشی از جمله روش‌های جدید برای الگوریتم‌های ابتکاری است که با الهام از قانون جاذبه و مفهوم جرم در طبیعت بنا نهاده شده است.

در این پژوهش، پیشنهاد استفاده از نسخه اصلاحی الگوریتم جست‌وجوی گرانشی به نام CGSA برای آموزش شبکه عصبی MLP به‌منظور پیش‌بینی میزان غلظت آلاینده  $O_3$  در هوای شهر تهران ارائه شد. بدین ترتیب می‌توان با جست‌وجوی بهترین وزن‌ها برای شبکه عصبی، به پیش‌بینی‌کننده مناسب برای آلاینده‌های هوا دست یافت. همچنین نسخه دودویی این الگوریتم (BGSA) برای



شکل (۹): عملکرد مدل پیشنهادی در پیش‌بینی غلظت آلاینده ازن - مقایسه مقادیر پیش‌بینی و خروجی واقعی



شکل (۱۰): رفتار همگرایی به‌هنگام آموزش شبکه عصبی پیش‌بین توسط الگوریتم‌های EBP، ABC، GA+SA، PSO، GSA و CGSA در ۱۰۰ بار تکرار الگوریتم

جدول (۴): MSE در شرایط آموزش شبکه عصبی پیش‌بین توسط الگوریتم‌های GSA, PSO, GA+SA, ABC, EBP و CGSA

MSE	نام الگوریتم
۰/۰۰۵۵	پس‌انتشار خطا (EBP)
۰/۰۰۲۳	اجتماع زنبور عسل مصنوعی (ABC)
۰/۰۰۳۷	ترکیب وراثتی و شبیه‌سازی تبرید (GA+SA)
۰/۰۰۳۶	بهینه‌سازی ازدحام ذرات (PSO)
۰/۰۰۱۹	جستجوی گرانشی (GSA)
۰/۰۰۱۷	نسخه آشوب‌گونه جستجوی گرانشی (CGSA)
۰/۰۰۳۸	CGSA برای آموزش شبکه و عدم استفاده از BGSA برای انتخاب ویژگی

در این باره، میزان MSE در تخمین توسط هریک از روش‌های مذکور با فرض به‌کارگیری BGSA برای انتخاب ویژگی، در جدول (۴) ارائه شده است. همچنین MSE در شرایطی که BGSA برای انتخاب ویژگی به‌کار گرفته نشود و از CGSA برای آموزش شبکه استفاده شود، در سطر آخر جدول (۴) گزارش شده است. همان‌گونه که مشاهده می‌شود، در شرایط شبیه‌سازی مشابه، CGSA عملکرد بهتری را نتیجه می‌دهد. همچنین حذف ویژگی‌های با اهمیت کمتر توسط

## مراجع

- [1] Sajani, S. Z., Scotto, F., Lauriola, P., Galassi, F., Montanari, A., "Urban air pollution monitoring and correlation properties between fixed-site stations", Air & Waste Management Association Vol. 54, No. 10, pp. 1236-1241, 2004.
- [2] اشرفی. خسرو، هشیاری پور. غلامعلی، نجار اعرابی. بایک، کشاورزی شیرازی. هما، «پیش‌بینی روزانه غلظت کربن منوکسید با استفاده از مدل تلفیقی انتخاب پیشرو - عصبی فازی براساس تحلیل پایداری جو، بررسی موردی: تهران»، مجله فیزیک زمین و فضا، دوره ۳۸، شماره ۲، ص ۱۸۳-۲۰۱، ۱۳۹۱.
- [3] منصور. غیاث‌الدین، «آلودگی هوا. منابع، اثرات و کنترل»، انتشارات دانشگاه تهران، چاپ اول، ۱۳۸۵.
- [4] Dempsey, F., "Observations of stratospheric O<sub>3</sub> intrusions in air quality monitoring data in Ontario, Canada", Atmospheric Environment, Vol. 98, pp. 111-122, Dec. 2014.
- [5] Ha, Q.P., Wahid, H., Duc, H., Azzi, M., "Enhanced radial basis function neural networks for ozone level estimation", Neurocomputing, Vol. 155, pp. 62-70, May 2015.
- [6] Rasmussen, D.J., Fiore, A.M., Naik, V., Horowitz, L.W., McGinnis, S.J., Schultz, M.G., "Surface ozone-temperature relationships in the Eastern US: a monthly climatology for evaluating chemistry-

BGSA منجر به بهبود عملکرد مدل پیش‌بین شده است. شکل (۱۰) نیز رفتار همگرایی روش‌های مذکور را طی ۱۰۰ بار تکرار نمایش می‌دهد. در این مورد نیز CGSA رفتار همگرایی را نشان می‌دهد.

باتوجه به اینکه ابزار پیش‌بینی در این مقاله، شبکه عصبی مصنوعی است و آموزش استاندارد این شبکه با الگوریتم EBP مشکل گرفتاری در کمینه‌های محلی را در برخی مسائل تقریب تابع و نیز طولانی بودن روال همگرایی به جواب را به دنبال دارد؛ لذا روش‌های بهینه‌سازی هوشمند که عملکرد بهتری را از خود نشان داده‌اند، در قالب یک مطالعه قیاسی در این مقاله مورد استفاده قرار گرفتند. نتایج نیز نشان داد که CGSA عملکرد موفق‌تری را از لحاظ میزان خطا نسبت به سایر روش‌ها دارد (جدول ۴). شایان ذکر است که پارامترهای این روش‌ها با توجه به مراجع مربوط در بازه مناسب پیشنهادی انتخاب شده؛ لذا بررسی این روش‌ها در قالب این مطالعه قیاسی به منظور برآورد عملکرد آن‌ها در رسیدن به هدف نهایی این پژوهش در پیش‌بینی موفق میزان غلظت آلاینده O<sub>3</sub> انجام شد.

- climate models*", Atmospheric Environment, Vol. 47, pp. 142-153, Feb. 2012.
- [7] Castellano, M., Franco, A., Cartelle, D., Febrero, M., Roca, E., "Identification of  $NO_x$  and ozone episodes and estimation of ozone by statistical analysis", Water, Air, & Soil Pollution, Vol. 198, No. 1, pp. 95-110, 2009.
- [8] Davis, J., Cox, W., Reff, A., Dolwick, P., "A comparison of CMAQ-based and observation-based statistical models relating ozone to meteorological parameters", Atmospheric Environment, Vol. 45, No. 20, pp. 3481-3487, 2011.
- [9] Agirre-Basurko, E., Ibarra-Berastegi, G., Madariaga, I., "Regression and multilayer perceptron-based models to forecast hourly  $O_3$  and  $NO_2$  levels in the Bilbao area", Environmental Modelling & Software, Vol. 21, No. 4, pp. 430-446, 2006.
- [10] Heo, J.S., Kim, D.S., "A new method of ozone forecasting using fuzzy expert and neural network systems", Science of The Total Environment, Vol. 325, No. 1-3, pp. 221-237, 2004.
- [11] Domanska, D., Wojtylak, M., "Explorative forecasting of air pollution", Atmospheric Environment, Vol. 92, pp. 19-30, Aug. 2014.
- [۱۲] علیاری شوره‌دلی. مهدی، تشنه‌لب. محمد، خاکی صدیق. علی، «پیش‌بینی کوتاه‌مدت آلودگی هوا به کمک شبکه‌های عصبی پرسپترون چندلایه، خط حافظه‌دار تأخیر، گاما و ANFIS با روش‌های ترکیبی آموزش مبتنی بر PSO»، مجله کنترل، جلد ۲، شماره ۱، ص ۱-۱۹، ۱۳۸۷.
- [۱۳] بوداقپور. سیامک، چرخستانی. امیر، «پیش‌بینی میزان غلظت آلاینده‌های هوای تهران با استفاده از شبکه عصبی مصنوعی»، علوم و تکنولوژی محیط زیست، دوره ۱۳، شماره ۱، ص ۱-۱۰، ۱۳۹۰.
- [14] Ozbay, B., Keskin, G.A., Dogruparmak, S.C., Ayberk, S., "Predicting tropospheric ozone concentrations in different temporal scales by using multilayer perceptron models", Ecological Informatics, Vol. 6, No. 3-4, pp. 242-247, 2011.
- [15] Salcedo-Sanz, S., Camacho, J.L., Pérez-Bellido, Á.M., Ortiz-García, E.G., Portilla-Figuera, A., Hernández-Martín, E., "Improving the prediction of average total ozone in column over the Iberian Peninsula using neural networks banks", Neurocomputing, Vol. 74, No. 9, pp. 1492-1496, 2011.
- [16] Biancofiore, F., Verdecchia, M., Di Carlo, P., Tomassetti, B., Aruffo, E., Busilacchio, M., Bianco, S., Di Tommaso, S., Colangeli, C., "Analysis of surface ozone using a recurrent neural network", Science of The Total Environment, Vol. 514, pp. 379-387, May 2015.
- [17] Nayeb Yazdi, M., Delavarráfiee, M., Arhami, M., "Evaluating near highway air pollutant levels and estimating emission factors: Case study of Tehran, Iran", Science of The Total Environment, Vol. 538, pp. 375-384, Dec. 2015.
- [18] Givehchi, R., Arhami, M., Tajrishy, M., "Contribution of the Middle Eastern dust source areas to  $PM_{10}$  levels in urban receptors: Case study of Tehran, Iran", Atmospheric Environment, Vol. 75, pp. 287-295, Aug. 2013.
- [19] Arhami, M., Kamali, N., Rajabi, M.M., "Predicting hourly air pollutant levels using artificial neural networks coupled with uncertainty analysis by Monte Carlo simulations", Environmental Science Pollution Research, Vol. 20, No. 7, pp. 4777-4789, 2013.
- [20] Chan, K.Y., L. Jian, "Identification of significant factors for air pollution levels using a neural network based knowledge discovery system", Neurocomputing, Vol. 99, pp. 564-569, Jan. 2013.
- [21] Luna, A.S., Paredes, M.L.L., de Oliveira, G.C.G., Corrêa, S.M., "Prediction of ozone concentration in tropospheric levels using artificial neural networks and support vector machine at Rio de Janeiro, Brazil", Atmospheric Environment, Vol. 98, pp. 98-104, Dec. 2014.
- [22] Ju, F.Y., Hong, W.C., "Application of seasonal SVR with chaotic gravitational search algorithm in electricity forecasting", Applied Mathematical Modelling, Vol. 37, No. 23, pp. 9643-9651, 2013.
- [23] Li, C., Zhou, J., Xiao, J., Xiao, H., "Hydraulic turbine governing system identification using T-S fuzzy model optimized by chaotic gravitational search algorithm", Engineering Applications of

- Artificial Intelligence, Vol. 26, No. 9, pp. 2073-2082, 2013.
- [24] Li, C., Zhou, J., Xiao, J., Xiao, H., "Parameters identification of chaotic system by chaotic gravitational search algorithm", *Chaos, Solitons & Fractals*, Vol. 45, No. 4, pp. 539-547, 2012.
- [۲۵] ذوقی. محمدجواد، سعیدی. محسن، «پیش‌بینی روزانه غلظت دی‌اکسید گوگرد در یک ناحیه شهری با استفاده از شبکه عصبی مصنوعی»، دومین همایش و نمایشگاه تخصصی مهندسی محیط زیست، دانشگاه تهران، ۱۳۸۷.
- [26] Rashedi, E., Nezamabadi-pour, H., Saryazdi, S., "BGSA: Binary Gravitational Search Algorithm", *Natural Computing*, Vol. 9, No. 3, pp. 727-745, 2010.
- [27] Hooyberghs, J., Mensink, C., Dumont, G.; Fierens, F., Brasseur, O., "A neural network forecast for daily average PM<sub>10</sub> concentrations in Belgium", *Atmospheric Environment*, Vol. 39, No. 18, pp. 3279-3289, 2005.
- [28] Rojas, R., *Neural Networks: A Systematic Introduction*, Springer-Verlag, Berlin, 1996.
- [29] Karaboga, D. *An Idea Based on Honey Bee Swarm for Numerical Optimization*, Technical Report-TR06, Erciyes University, Oct. 2005.
- [30] Goldberg, D.E., *Genetic Algorithms in Search, Optimization and Machine Learning*, Addison-Wesley Longman Publishing Co., Boston, MA, USA, 1989.
- [31] Kirkpatrick, S., Gelatto, C. D., Vecchi, M. P., "Optimization by simulated annealing", *Science*, Vol. 220, No. 4598, pp. 671-680, 1983.
- [32] Granville, V., Krivanek, M., Rasson, J.-P., "Simulated annealing: A proof of convergence", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 16, No. 6, pp. 652-656, 1994.
- [33] Kennedy, J., Eberhart, R., Shi, Y., *Swarm Intelligence*, Morgan Kaufmann, San Francisco, CA, USA, 2001.
- [34] Rashedi, E., Nezamabadi-pour, H., Saryazdi, S., "GSA: A Gravitational Search Algorithm", *Information Sciences*, Vol. 179, No. 13, pp. 2232-2248, 2009.
- [۳۵] ده‌باشیان. مریم، ظهیری. سیدحمید، «آموزش شبکه عصبی MLP در فشرده‌سازی تصاویر با استفاده از روش GSA»، فصل‌نامه فناوری اطلاعات و ارتباطات ایران، سال دوم، شماره‌های ۵ و ۶، صفحه ۴۵-۵۳، ۱۳۸۹.
- [۳۶] قنبری. نجمه، رضوی. سیدمحمد، نبوی کهریزی. سید حسن، «ارائه یک روش هوشمند انتخاب ویژگی مبتنی بر الگوریتم جستجوی گرانشی باینری در سیستم بازشناسی ارقام دستنویس فارسی»، نشریه مهندسی برق و مهندسی کامپیوتر ایران، سال ۹، شماره ۱، ص ۲۹-۳۶، ۱۳۹۰.
- [۳۷] راشدی. عصمت، نظام‌آبادی‌پور. حسین، «طراحی فیلترهای IIR به وسیله الگوریتم جستجوی گرانشی»، شانزدهمین کنفرانس مهندسی برق ایران، دانشگاه تربیت مدرس، جلد اول، ص ۴۶۹-۴۷۴، تهران، اردیبهشت ۱۳۸۷.
- [۳۸] راشدی. عصمت، نظام‌آبادی‌پور. حسین، «انتخاب ویژگی با استفاده از الگوریتم جستجوی گرانشی»، سومین کنفرانس فناوری اطلاعات و دانش، دانشگاه فردوسی مشهد، ص ۵۱-۶۱، ۱۳۸۶.
- [39] Rashedi, E., Nezamabadi-pour, H., Saryazdi, S., "Allocation of static VAR compensator using gravitational search algorithm", First Joint Congress on Fuzzy and Intelligence Systems, Ferdowsi University of Mashhad, Iran, Aug 2007.
- [40] Sheikhan, M., Jadidi, Z., "Flow-based anomaly detection in high-speed links using modified GSA-optimized neural network", *Neural Computing and Applications*, Vol. 24, No. 3, pp. 599-611, 2014.
- [۳۶] ده‌باشیان. مریم، ظهیری. سیدحمید، «الگوریتم جستجوی گرانشی نخبه‌گرای پیشرفته»، اولین کنفرانس انرژی‌های تجدیدپذیر و تولید پراکنده ایران، دانشگاه بیرجند، ص ۳۵-۴۵، ۱۳۸۸.
- [۳۷] ده‌باشیان. مریم، ظهیری. سیدحمید، «MOGSA: روشی جدید در بهینه‌سازی چندهدفه مبتنی بر الگوریتم جستجوی گرانشی»، شانزدهمین کنفرانس ملی سالانه انجمن کامپیوتر ایران، دانشگاه صنعتی شریف، ص ۵۰۲-۵۰۷، ۱۳۸۹.

[۳۵] ده‌باشیان. مریم، ظهیری. سیدحمید، «آموزش شبکه

[۳۸] ده‌باشیان. مریم، ظهیری. سیدحمید، «آموزش شبکه

عصبی MLP در طبقه‌بندی داده‌ها با استفاده از روش

GSA»، نشریه مهندسی برق و مهندسی کامپیوتر ایران،

سال ۸، شماره ۳، ص ۲۶۷-۲۷۴، ۱۳۸۹.



دریافت مقاله: ۱۳۹۵/۱۲/۱۶

پذیرش مقاله: ۱۳۹۶/۰۶/۱۱

## کاربرد سیستم‌های آنالیز تصویر در فرایند فلوتاسیون

فردیس نخعی<sup>۱</sup>، مهدی ایران‌نژاد<sup>۲\*</sup>، سیما محمدنژاد<sup>۳</sup>

<sup>۱</sup> دانشجوی دکتری فرآوری مواد معدنی، دانشکده مهندسی معدن و متالورژی، دانشگاه صنعتی امیرکبیر، تهران

fardis\_nakhaei@aut.ac.ir

<sup>۲</sup> دانشیار دانشکده مهندسی معدن و متالورژی، دانشگاه صنعتی امیرکبیر، تهران

iranajad@aut.ac.ir

<sup>۳</sup> استادیار دانشکده فنی و مهندسی، دانشگاه تربیت مدرس، تهران

sima.mnejad@gmail.com

### چکیده

فرایند فلوتاسیون رایج‌ترین روش در جدایش کانی‌های باارزش از باطله در فرآوری مواد معدنی است. ماهیت تغییرپذیر خوراک ورودی، تأثیر متقابل متغیرها و ضعف تجهیزات دقیق اندازه‌گیری، توسعه روش‌های پایش و کنترل پیوسته مدارهای فلوتاسیون را به موضوع مهمی تبدیل کرده است. امروزه با توسعه تکنولوژی، سیستم‌های بینایی ماشین مبتنی بر روش‌های پردازش تصویر به‌عنوان یک ابزار شناسایی سریع، ارزان و با امنیت بالا، در صنایع فرآوری مواد معدنی مورد توجه صنایع و محققان قرار گرفته است. ظاهر سطح کف فلوتاسیون، حاوی اطلاعات مهمی از فرایند است که به‌خوبی شرایط عملیاتی فرایند را بازتاب می‌کند. توزیع ابعادی حباب کف شاخصی از پایداری و سرعت کف است که بهترین عامل برای تخمین کارایی و اهداف کنترلی عملیات فلوتاسیون است. این مقاله، مرور به‌روزرسانی‌شده‌ای از رایج‌ترین روش‌های تخمین ابعاد حباب کف فلوتاسیون به‌همراه مزایا و محدودیت‌های آن‌ها و ایده‌هایی برای تحقیقات آتی در این حوزه را ارائه می‌کند. همچنین ارتباط میان عیار و بازیابی کنسانتره با ابعاد حباب کف بیان می‌شود.

واژه‌های کلیدی: فلوتاسیون، کف، پردازش تصویر، ابعاد حباب، کنترل، عیار و بازیابی.

## ۱. مقدمه

فرایند فلوتاسیون یک روش جدایش فیزیکوشیمیایی است که از وجود اختلاف در خواص سطحی کانی‌های باارزش و باطله استفاده می‌کند [۱]. فرایند فلوتاسیون به‌شدت توسط بسیاری از عوامل مربوط به ویژگی‌های خوراک ورودی (عیار، توزیع ابعادی ذرات، درجه آزادی، خواص سطحی و...) و متغیرهای فرایند (مقدار مواد شیمیایی، pH و...) تحت تأثیر قرار می‌گیرد [۲].

باتوجه به تعداد زیاد متغیرهای فرایند و همچنین ماهیت تغییرپذیر خوراک ورودی، پایش و کنترل فرایند فلوتاسیون بسیار مشکل و پیچیده است. همچنین براساس گزارش‌های ارائه‌شده توسط محققان مختلف، ایجاد یک مدل قابل اطمینان برای شبیه‌سازی یا کنترل فرایند فلوتاسیون دشوار است [۳-۶]. به‌طور خلاصه مشکلات موجود در کنترل فرایند فلوتاسیون ناشی از موارد زیر است [۷]:

۱. تأثیر متقابل متغیرهای عملیاتی مربوط به عملیات نرم‌کنی، مواد شیمیایی، نرخ جریان هوا و... که بر کارایی نهایی سیستم تأثیر گذارند؛
۲. تغییرات اجتناب‌ناپذیر در ویژگی‌های کانه ورودی در بسیاری از مدارهای صنعتی که اجرای هر سیستم کنترلی را مشکل می‌سازد؛
۳. وجود تأخیرهای بلندمدت بین تغییرات سیستم‌های کنترل و ظهور تأثیرات قابل مشاهده در فرایند و بالعکس. به‌عبارت دیگر، تأخیر بین تغییرات عمگرهای متالورژیکی و پارامترهای تحت پایش فرایند فلوتاسیون. در مطالعات اولیه از رفتار فاز کف در فرایندهای فلوتاسیون مشاهده شده است که تغییرات ظاهری سطح کف، کلید درک رفتار کلی سیستم‌های فلوتاسیون است و می‌توان ویژگی ظاهری سطح کف را به‌عنوان یک شاخص مؤثر از وضعیت عملکرد فرایند استفاده کرد [۸ و ۹].

در بسیاری از واحدهای فلوتاسیون، متغیرهای عملیاتی از قبیل مواد شیمیایی، جریان هوا و سطح پالپ، اساساً از طریق مشاهدات صورت‌گرفته از ویژگی‌های سطحی کف توسط

کاربران باتجربه تنظیم می‌شود [۱۰ و ۱۱]. باوجوداین، مشکلات بسیاری در کنترل و عملیات فرایند فلوتاسیون مبتنی بر مشاهدات صورت‌گرفته توسط چشم انسان وجود دارد [۱۲]:

۱. مشاهدات کاربران از سطح کف، کیفی و فاقد اندازه‌گیری‌های کمی است. هریک از کاربران ممکن است درک متفاوتی از ویژگی‌های بصری داشته باشند و هیچ معیار مشخصی برای قضاوت درباره وضعیت کف وجود ندارد. حتی درباره وضعیت‌های تولید کف فلوتاسیون در شرایط و زمان یکسان، کاربران مختلف احتمالاً نتایج کاملاً متفاوتی را گزارش می‌کنند.

۲. کاربران قادر به پایش مؤثر کل مدار فلوتاسیون نیستند؛ زیرا کل مدار فلوتاسیون یک فرایند وسیع و پیوسته است که شامل چندین بانک سلول فلوتاسیون است. علاوه‌برآن، خستگی کاربران به‌واسطه مشاهدات طولانی، اجتناب‌ناپذیر است و در نتیجه نمی‌توانند وضعیت کف را با مشاهدات لحظه‌ای به‌طور صحیح شناسایی کنند. بنابراین، درک و تفسیر فاز پیچیده کف منحصراً از طریق مشاهدات بصری کاربران، کاملاً دشوار و غیرممکن است.

هدف نهایی در هر فرایند کانه‌آرایی، حفظ کیفیت بالای محصول نهایی به‌همراه بهبود نرخ تولید و سود اقتصادی در سایه کنترل و اتوماسیون است. نتایج دقیق کارایی فلوتاسیون (عیار و بازیابی) تنها پس از نمونه‌برداری، فیلتراسیون، خشک‌کردن، آماده‌سازی و آنالیز شیمیایی به‌دست آورده می‌شود [۱۳]. بنابراین یافتن ارتباط دقیق بین متغیرهای فلوتاسیون و نتایج عیار کنسانتره و باطله، بسیار زمان‌بر است. به‌عبارت دیگر، عملکرد متالورژیکی منعکس‌کننده کارایی دقیق فلوتاسیون را نمی‌توان به‌صورت آنلاین تعیین کرد. وضعیت بدتر زمانی است که خوراک ورودی فلوتاسیون دارای نوسانات زیادی باشد. بدین منظور، اندازه‌گیری‌های آنلاین عیار عناصر در جریان‌های فلوتاسیون توسط تحلیل‌گرهای فلورسانس اشعه ایکس (XRF) برای کنترل مؤثر فلوتاسیون اهمیت بسزایی دارد [۱ و ۸]. قیمت زیاد، دقت نسبتاً پایین، هزینه‌های بالای نگهداری آن و اندازه‌گیری برآیند عملکرد سری سلول‌های فلوتاسیون به‌جای

بررسی قرار می‌شوند. همچنین چالش‌های موجود درباره این روش‌ها بحث می‌شود. این منبع می‌تواند کمک شایانی به محققان و کاربران واحدهای فرآوری مواد معدنی برای درک بهتر و توسعه کنترل فرایند ارائه کند.

## ۲. سیستم تصویربرداری دیجیتال

### ۲.۱. اکتساب تصاویر

اولین گام در به‌کارگیری یک سیستم بینایی ماشین، تهیه یک تصویر دیجیتال است. این عمل می‌تواند با استفاده از یک دوربین دیجیتال انجام شود. دوربین دیجیتال یک دستگاه الکترونیکی است که برای گرفتن عکس و ذخیره آن به‌جای فیلم عکاسی، از حسگرهای حساس به نور معمولاً از نوع دستگاه بار جفت‌کننده (CCD) یا حسگرهای نیمه‌رسانای اکسید فلزی (CMOS) استفاده می‌کند [۲۵]. این دو ابزار، ذاتاً یک هدف را دنبال می‌کند و آن تبدیل تصویر بصری به سیگنال‌های الکتریکی است که در نهایت، تصویر دیجیتال را ایجاد می‌کند.

در فرایند پردازش تصویر، سیستم روشنایی (نورپردازی) از اهمیت زیادی برخوردار است؛ زیرا با اعمال سیستم نورپردازی هوشمندانه، می‌توان بر مشکلات رایج نظیر انعکاس، سایه‌اندازی و نویز فائق آمد. روشنایی نامناسب می‌تواند منجر به انعکاس شدید یا تغییر غیریکنواخت نور در تصویر گردد. شفافیت تصویر، تکرارپذیری و قابلیت اطمینان یک سیستم بینایی ماشین به نوع منبع نور، شدت روشنایی، روش تأمین روشنایی، شکل پرتو و رنگ نور وابسته است [۲۶ و ۲۷]. بر همین اساس، انتخاب مؤلفه‌های سیستم تصویربرداری بسیار مهم است؛ زیرا بر شناسایی الگو و کارایی طبقه‌بندی تصاویر تأثیرگذار است.

شدت منبع نور باید یکنواخت و کنترل‌شده باشد. منابع نوری معمول عبارت‌اند از: لامپ‌های رشته‌ای، فلورسنت، هالوژن، ال ای دی (LED)، لامپ لوله اشعه ایکس و مادون قرمز [۲۸]. تعیین یک منبع روشنایی ایدئال ساده نیست و متکی بر ماهیت شیء یا فرایند است.

### ۲.۲. ماهیت تصویر دیجیتال

یک تصویر مقیاس خاکستری دیجیتال می‌تواند به شکل یک تابع

تک‌تک سلول‌ها از مهم‌ترین مشکلات مربوط به تجهیزات اندازه‌گیری پیوسته عیار فلزات است [۱۴ و ۱۵].

در حال حاضر، با توسعه سریع ابزارهای محاسباتی، می‌توان برای غلبه بر این مشکلات، از روش‌های تصویربرداری دیجیتال از کف استفاده کرد [۱۶-۲۲]. ظاهر بصری سطح کف را می‌توان با استفاده از روش‌های پردازش تصویر دیجیتال که قادر به توصیف ویژگی‌های مورفولوژیکی [۲۳] و رنگی [۲۴] تصویرند، تحلیل نمود. ابعاد حباب، سرعت کف (جابجایی حباب‌ها در سطح کف)، رنگ و پایداری کف معمولاً به‌عنوان ویژگی‌های بصری حائز اهمیت در کنترل و پایش عملیات فلوتاسیون در نظر گرفته می‌شوند. این ویژگی‌ها با عوامل متالورژیکی اندازه‌گیری‌شده در واحد فلوتاسیون ارتباط معناداری دارند. این رابطه می‌تواند به کاربران فرایند در تحلیل، پایش و کنترل عملیات فلوتاسیون کمک شایانی بکند. براساس تحقیقات گذشته، مزیت‌های پایش و کنترل فرایند فلوتاسیون با سیستم‌های بینایی ماشین عبارت است از:

- کاهش هزینه‌های تولید؛
- اجرا و کنترل عملیات از راه دور؛
- درک بهتر فرایند و بهبود دانش کاربران واحدهای عملیاتی؛
- توانایی درک و مدیریت بهتر در مواجهه با مشکلات پیچیده؛
- کاهش هدرروی کانی‌های باارزش در فرایند؛
- بهبود کیفیت محصول و کارایی فرایند فلوتاسیون؛
- کاهش اقدامات پرخطر.

در پایش و کنترل خودکار فرایندهای فلوتاسیون، وجود یک رویکرد قابل اطمینان و سازگار برای کمی‌سازی ویژگی‌های کف ضروری است. توزیع ابعادی حباب کف ویژگی فیزیکی معنی‌داری است که می‌تواند نشان‌دهنده بار حباب، کیفیت و نوع کانی متصل‌شده به حباب و در مجموع، وضعیت فرایند فلوتاسیون باشد. در این مقاله، روش‌های مختلف استخراج داده‌ها از تصاویر کف (با تمرکز بر آخرین پیشرفت‌ها) برای تخمین ابعاد حباب‌ها و به‌دنبال آن، ارزیابی کارایی فلوتاسیون

هر پیکسل دارای مقدار منحصربه‌فرد است و نمی‌تواند ویژگی‌های تصویر را طبقه‌بندی کند. تحلیل تصویر، بخشی از یک حوزه گسترده‌تر است که با عنوان پردازش تصویر شناخته می‌شود و ایده اصلی آن، اصلاح اطلاعات موجود در یک تصویر برای بهبود کیفیت بصری و استخراج اطلاعات سودمند است. تحلیل تصاویر مبتنی بر اختلاف ویژگی‌های تصویر نظیر اندازه، شکل، بافت و... است. عملیات پردازش تصویر را می‌توان به صورت زیر تقسیم‌بندی کرد [۳۰]:

- پیش‌پردازش تصویر که شامل بهبود کیفیت بصری تصویر از طریق کاهش نویز، ساده‌سازی، تشخیص لبه‌ها و افزایش قابلیت اعتماد به تحلیل تصاویر می‌شود. پس از پیش‌پردازش تصویر، ویژگی‌های تصاویر استخراج می‌شود.
- فشرده‌سازی تصویر که از طریق حذف بخش‌های زائد موجود در تصویر، ملزومات حافظه‌ای را کاهش می‌دهد.
- تحلیل تصاویر که معمولاً به مقادیر عددی یا هیستوگرام‌های مربوط به ویژگی‌های تصویر اطلاق می‌شود که از آن‌ها برای طبقه‌بندی، پایش و کنترل برخی از خواص کیفی محصول موجود در تصویر استفاده می‌شود.

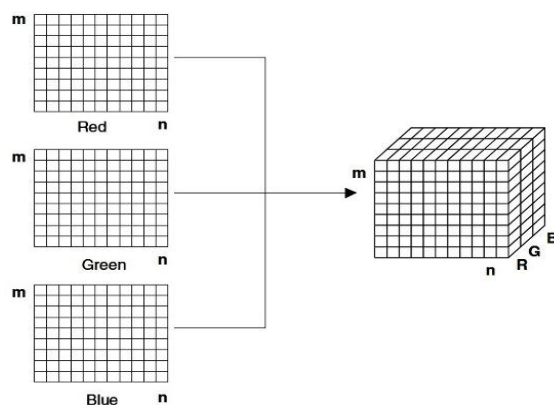
### ۳. استخراج ویژگی از تصاویر کف

چندین مطالعه بنیادی با استفاده از تحلیل کیفی فاز کف، تأکید کرده‌اند که می‌توان از ساختار کف به عنوان یک معیار مناسب برای ارزیابی کارایی سیستم فلوتاسیون استفاده کرد [۱۷ و ۳۲]. مولمان<sup>۱</sup> و همکاران [۱۷] بیان کردند که روش‌های کیفی طبقه‌بندی کف را نه تنها باید براساس مشاهدات ساده کف بلکه بر مبنای یک تحلیل تفصیلی از رابطه بین ظاهر کف کارایی فرایند پایه‌گذاری کرد. براساس همین استدلال، آن‌ها سه طبقه اصلی کف شامل کف ایدئال، کف روان و کف چسبنده را بر مبنای این فرض شناسایی کردند که تحرک کف، پایداری کف و ابعاد متوسط حباب مهم‌ترین ویژگی‌های کف هستند.

دو بعدی گسسته  $f(x,y)$  تعریف شود که در آن،  $x$  و  $y$  مختصات مکانی (در روی صفحه) هستند و دامنه  $f$  در هر زوج از مختصات  $(x,y)$  شدت روشنایی یا سطح خاکستری تصویر، در آن نقطه نامیده می‌شود. یک تصویر مقیاس خاکستری فقط شدت روشنایی را اندازه‌گیری می‌کند. در تصاویر دیجیتالی، کوچک‌ترین جزء ساختاری یک تصویر (هر مختصات مجزا) پیکسل نامیده می‌شود [۲۹]. هر پیکسل، یک عدد اسکالر متناسب با روشنایی است.

برای نمایش یک تصویر  $M \times N$  از یک آرایه دو بعدی (ماتریس) با  $M$  سطر و  $N$  ستون استفاده می‌شود. مقدار هر عنصر از آرایه، نشان‌دهنده شدت روشنایی تصویر در آن نقطه است. تنها در تصاویر سیاه و سفید، هر عنصر آرایه یک مقدار هشتمین است که می‌تواند مقداری بین ۰ و ۲۵۵ داشته باشد. مقدار صفر نشان‌دهنده رنگ تیره (سیاه) و مقدار ۲۵۵ نشان‌دهنده رنگ روشن (سفید) است [۲۹].

مطالعات اولیه درباره کاربرد پردازش تصویر در صنایع مختلف، معمولاً روی تصاویر مقیاس خاکستری انجام شده است. از سال ۱۹۸۵ به بعد، مختصات RGB (قرمز-سبز-آبی) به‌ازای هر پیکسل در دسترس قرار گرفتند [۳۰]. همان‌گونه که در شکل (۱) نشان داده می‌شود، تصویر رنگی RGB به صورت یک ماتریس سه بعدی در نظر گرفته می‌شود. این بدان معناست که مؤلفه‌های قرمز، سبز و آبی یک تصویر دیجیتال در سه ماتریس متمایز ذخیره می‌شود. برای ایجاد یک ماتریس سه بعدی نشان‌دهنده تصویر، این سه ماتریس روی یکدیگر واقع می‌شوند.



شکل (۱): ماهیت تصاویر دیجیتالی RGB [۳۱]

شود. برای غلبه بر این مشکلات، توسعه سریع ابزار دقیق و زیرساخت‌های رایانه‌ای در دهه گذشته، منجر به توسعه سیستم‌های بینایی ماشین برای تحلیل تصاویر کف شده است. از زمانی که کارهای ابتدایی توسط دژاگر و همکاران [۳۳] و مولمان و همکاران [۳۴] انجام گرفته است، این سیستم‌ها با رشد سریع توسعه و تجاری‌سازی مواجه شده‌اند.

به طور کلی، یک تصویر کف دربردارنده اطلاعات شامل شکل، اندازه، بافت و رنگ است. اطلاعات شکل را می‌توان از طریق محاسبه توصیف‌گرهای مختلف شکل (مانند تبدیل فوریه) استخراج کرد. اطلاعات بافت به وسیله محاسبه برخی ویژگی‌های آماری (نظیر ماتریس هم‌رخداد، هیستوگرام، آنتروپی، ثبات، همواری) استخراج می‌شود. اطلاعات رنگی معمولاً از فضاهاى رنگی مانند RGB یا HIS استخراج می‌شود [۳۵].

ویژگی‌های این کف‌ها در جدول (۱) به‌طور خلاصه بیان شده است.

نتایج نشان داده است که ویسکوزیته کف (بازتاب پایداری و سرعت کف) و ابعاد حباب از مهم‌ترین ویژگی‌ها در ارزیابی بصری کف است و شاخص بسیار سودمندی از فرایندهای رخ داده در فاز کف موجود در فلوتاسیون است. با وجود اینکه رویکرد پیشنهادشده توسط مولمان و همکاران [۱۷]، مبنای بسیار مناسبی را برای طبقه‌بندی تصاویر کف ارائه می‌کند، درباره توسعه یک سیستم طبقه‌بندی خودکار برای پایش و کنترل فاز کف، دارای ضعف‌های اساسی است. این موضوع موردانتظار است؛ زیرا رویکرد فوق با هدف طراحی یک سیستم بینایی ماشین فلوتاسیون توسعه نیافته است. برای یک سیستم طبقه‌بندی دقیق و نظام‌مند، بایستی مجموعه‌ای از اصول و قوانین برای انتخاب یک رویکرد استخراج ویژگی خاص فرمول‌نویسی

جدول (۱): سه نوع عمده کف و ارتباط آن‌ها با مشخصات کف

نوع کف	ابعاد متوسط حباب	تحرك	پایداری	بافت کلی	دلایل احتمالی
ایدئال	متوسط	متوسط	متوسط	حباب‌های چندوجهی، فشرده نزدیک به هم با پنجره سفید کوچک مشخص در بالای آن، که نشان‌دهنده تعادل بین آب و محتوای کانی است.	
روان	کوچک	بالا	پایین	حباب‌های آبدار، کروی، با اتصال ضعیف به یکدیگر حاوی مقدار کمی از کانی	نرخ کف‌ساز بسیار پایین، سطح پالپ بسیار بالا، دانسیته پالپ بسیار پایین، اعمال نرخ جریان مواد شیمیایی نادرست
چسبنده	بزرگ	پایین	بالا	ویسکوز، بیضوی، حباب‌های نزدیک به هم و فشرده با بار کف بالا	نرخ کف‌ساز بسیار بالا، سطح پالپ بسیار پایین، دانسیته پالپ بسیار بالا، اعمال نرخ جریان مواد شیمیایی نادرست


بازتابی از بار کف و نرخ ترکیدن حباب است [۳۶]. بنابراین تخمین بلادرنگ ابعاد متوسط حباب‌های سطح کف و ارائه مدل‌های پیش‌بینی عملکرد متالورژیکی بر پایه اطلاعات استخراج شده از تصاویر کف امری ضروری است. امروزه اندازه‌گیری ابعاد حباب‌های سطح کف از تصاویر به یکی از موضوعات بسیار مهم در عملیات فلوتاسیون تبدیل شده است. وودبرن<sup>۱</sup> و همکاران [۳۷] یک مدل سینتیکی فلوتاسیون

ویژگی‌های ساختاری کف، تأثیر قابل‌توجهی بر کارایی فرایند فلوتاسیون دارد و از آن به‌عنوان شاخص کلیدی در تنظیم متغیرهای عملیاتی استفاده می‌شود. از این رو، مهم‌ترین روش‌های تخمین ویژگی ساختاری کف (اندازه حباب) به‌طور کامل بررسی می‌گردد.

### ۱.۳. ویژگی ابعادی حباب کف

ابعاد حباب ( $D_b$ ) در سطح کف، به‌شدت با شرایط عملیاتی و کارایی فرایند در ارتباط است [۱۷]؛ زیرا ابعاد حباب کف

زیاد به آن ختم می‌شود، حوزه آبریز گویند. آب‌پخشان در واقع نواحی تشکیل شده از حوزه‌های آبریز مجاور یکدیگر است.




شکل (۳): نمونه تک‌بعدی از قطعه‌بندی آب‌پخشان (نقاط مینیمم محلی سطح خاکستری حوضه آبریز و نقاط ماکزیمم، خطوط آب‌پخشان را نشان می‌دهد).

تعریف براساس غوطه‌وری: با فرض اینکه در هر کمینه ناحیه‌ای یک سوراخ ایجاد شود، با فرو بردن توپوگرافی از پایین در آب، آب از میان سوراخ‌ها با یک نرخ یکنواخت بالا می‌آید. زمانی که آب بالارونده در آبریزهای مجزای حوزه آبریز در شرف الحاق هستند، یک سد ساخته می‌شود تا از الحاق جلوگیری کند. فرو رفتن در آب سرانجام به مرحله‌ای می‌رسد که تنها بخش بالای سدها روی خط آب قابل مشاهده است. مرزهای این سد به خطوط تقسیم آب‌پخشان‌ها مربوط می‌شود. بنابراین آن‌ها مرزهای بسته‌ای هستند که توسط یک الگوریتم تقطیع آب‌پخشان استخراج شده‌اند [۴۵]. گام بعدی، محاسبه تعداد پیکسل‌ها و در نتیجه، تخمین سطح هر حباب در هر منطقه است.

بونیفیسی و همکاران [۹] روش قطعه‌بندی آب‌پخشان را به منظور اندازه‌گیری ساختار حباب‌های کف در یک واحد فلوتاسیون صنعتی مدار مس-سرب به کار گرفتند. آن‌ها پس از اعمال روش‌های بهبود تصویر و قطعه‌بندی که برای تشخیص حباب‌ها به صورت محدوده‌های مجزا ضروری است، اندازه‌گیری‌های مورفولوژیکی (سطح حباب، نسبت ابعاد کف) را از طریق متوسط‌گیری به دست آوردند. در شکل‌های (۴) و (۵) می‌توان مشاهده کرد که اندازه‌گیری سطح حباب با استفاده از روش آب‌پخشان، کف‌های دارای حباب‌های کوچک، بزرگ یا با ابعاد مختلط را به خوبی توصیف می‌کند. در شکل (۵)

مبتنی بر کف را توسعه داده‌اند که امکان پیش‌بینی نرخ‌های جرمی جریان را با معلوم بودن ابعاد متوسط حباب کف فراهم می‌کند. روش‌های مختلفی برای شناسایی ابعاد حباب کف ارائه شده‌اند که می‌توان به تقسیم بندی آب‌پخشان [۹، ۲۳ و ۳۸-۴۰]، شناسایی و ردیابی دره-لبه [۳۹]، طیف بافتی [۴۱ و ۴۲]، شناسایی نقاط سفید [۴۳] اشاره کرد.

در میان روش‌های گزارش شده، قطعه‌بندی تصویر (شکل ۲) با استفاده از روش‌های آب‌پخشان و شناسایی دره-لبه دارای بیشترین کاربردند [۴۴]. الگوریتم قطعه‌بندی به شدت به کیفیت تصویر وابسته است. در عمل، هریک از این روش‌ها مزایا و معایب خاص خود را دارند که در اینجا به آن پرداخته می‌شود.



شکل (۲): نمونه‌ای از تصویر کف تقسیم‌بندی شده [۱۹]



### ۱.۱.۳. الگوریتم آب‌پخشان

ایده اصلی قطعه‌بندی آب‌پخشان بر مبنای مفهوم شبیه‌سازی جریان‌های آب در یک نمایش توپوگرافی از شدت‌های تصویر، پایه‌گذاری شده است [۴۵].

همان‌طور که در شکل (۳) نشان داده می‌شود، شدت یک تصویر به وسیله یک پهنه توپوگرافی نمایش داده می‌شود که در آن، نقاط حدافل محلی معرف کف دره‌ها هستند و هر نقطه از تصویر بر همین اساس به صورت یک نقطه مرتفع لحاظ می‌شود. عموماً دو بیان کلی برای الگوریتم آب‌پخشان ارائه شده است: تعریف براساس خطوط دارای بیشترین شیب و تعریف براساس غوطه‌وری.


تعریف براساس خطوط دارای بیشترین شیب: با فرض اینکه یک قطره آب روی این سطح مرتفع بیفتد، این قطره مسیر بیشترین شیب را طی می‌کند تا به یک نقطه حدافل برسد. مجموعه‌ای از نقاط با شیب حدافل را که چند مسیر با شیب‌های

روش هایی نظیر آب پخشان سلسله مراتبی و ترکیب آن با شبکه عصبی و نیز ساده سازی و قرار دادن حد آستانه برای مقادیر زمینه، پیش از قطعه بندی برای حل مسئله بیش قطعه بندی گزارش شده است. اما کاربرد این الگوریتم های پیچیده در زمان واقعی و آنلاین، به دلیل حجم محاسبات بالا گزارش نشده است.





شکل (۵): تصاویر دیجیتال (۲۵۶×۲۵۶ پیکسل): (الف) حباب های طویل و (ب) حباب های گرد. (ج) نمونه های تصویر کف تحلیل شده در مقابل ابعاد متوسط حباب ها در کف [۱۴]

با وجود این، هنوز هم قطعه بندی بیش از حد تصویر می تواند در زمان اعمال الگوریتم آب پخشان به تصاویری با جزئیات بسیار زیاد، یک مشکل عمده باشد. برای مثال، تصویر کف ارائه شده از فرایند فلوتاسیون اکسید فسفر (شکل ۶) توسط لین و همکاران [۴۵] دارای جزئیات زیادی است و اختلاف معناداری با تصاویر کف گزارش شده در مقالات دیگر (شکل ۲ [۱۹]) دارد. شکل (۶ ب) اهمیت مشکل تقسیم بندی بیش از حد را در تصاویر کف با تعداد زیاد حباب های ریز را نشان می دهد که حتی با انتخاب دقیق پارامترها، نتایج ضعیفی حاصل می شود.



شکل (۶): (الف) تصویر کف با جزئیات زیاد، (ب) قطعه بندی آب پخشان تصویر کف [۴۱]


نسبت ابعاد متوسط حباب ها نشان داده شده است. مشاهده می شود که اندازه گیری های صورت گرفته به خوبی کف های با حباب های طویل و گرد را توصیف می کنند. نسبت تصویر (Aspect ratio) ابعاد حباب به صورت نسبت محور بزرگ و محور کوچک بیضی معادل حباب (نسبت تصویر حباب های گرد برابر با یک و برای حباب های بیضوی بیش از یک است) بیان می شود. بر اساس تحلیل های انجام شده، ارتباط زیادی بین ویژگی های مورفولوژیکی (سطح و نسبت تصویر ابعاد حباب) حاصل از روش های تصویربرداری دیجیتال و ویژگی های محاسبه شده به واسطه چشم انسان وجود دارد [۹].





شکل (۴): تصاویر دیجیتال (۳۸۴×۲۸۸ پیکسل) از سطوح کف: حباب های بزرگ (الف): مخلوط حباب های بزرگ و کوچک (ب): حباب های بسیار ریز (ج). (د) نمونه های تصویر کف آنالیز شده (۵۶ تصویر به عنوان مرجع) در مقابل سطح متوسط حباب ها در کف [۱۴]

عیب عمده روش آب پخشان، قطعه بندی بیش از حد تصویر است؛ زیرا برای هر نقطه مینیمم محلی یک حوضه آبریز ایجاد می شود. در بیش قطعه بندی، احتمال تقسیم حباب های بزرگ فلوتاسیون به حباب های کوچک تر وجود دارد که عمدتاً از نقاط روشن چندگانه روی حباب ها ناشی می شود. دلیل ایجاد این نقاط، شرایط روشنایی غیریکنواخت و تأثیر انعکاس نور مربوط به ذرات موجود بر روی سطح حباب است. رانگ و همکاران [۴۶] دریافتند که الگوریتم آب پخشان در سیستم تجاری Visio Froth به هنگام وجود حباب های بزرگ و کوچک در یک تصویر از کف، قادر به شناسایی دقیق حباب ها نیست. توسعه

فرایندی مختلف اعتبارسنجی شده و نتایج با یکدیگر مقایسه شده‌اند [۴۷]. نشانه‌های نهایی استخراج شده از تصویر کف در شکل (۸) نشان داده شده است. شکل (۹) نتایج قطعه‌بندی و منحنی‌های توزیع ابعادی حباب یک تصویر کف را با استفاده از دو روش مختلف نشان می‌دهد. مقایسه نتایج حاصل از الگوریتم اصلاح شده نشان داد که این روش، تخمین دقیق‌تری از مرزهای حباب در تصاویر کف را ارائه می‌کند و می‌تواند در اتوماسیون توصیف کف و سیستم‌های کنترل در مقیاس صنعتی استفاده شود [۴۷]. با وجود این، یکپارچه‌سازی عملیات پیش‌پردازش با سیستم کنترل زمان واقعی، از منظر محاسباتی بسیار دشوار است.



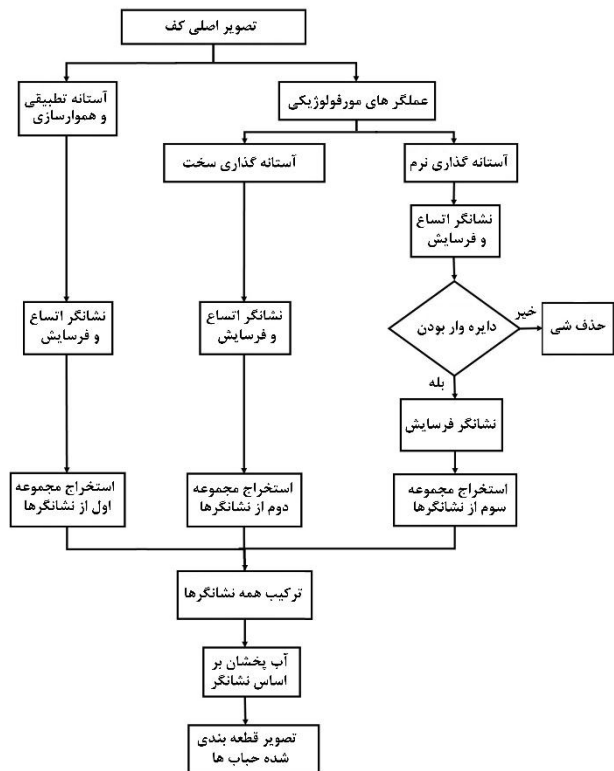
شکل (۸): (الف) تصویر اصلی کف، (ب) نشانه‌های اولیه استخراج شده توسط مهرشاد و مسینایی [۴۰] و (ج) نشانه‌های نهایی استخراج شده در تبدیل آب‌پخشان نشانه اصلاح شده توسط جاهدسراوانی و همکاران [۴۷]



شکل (۹): نتایج قطعه‌بندی با (الف) ویرایش دستی (برای کنترل و ارزیابی نتایج)، (ب) الگوریتم آب‌پخشان براساس نشانه اصلاح شده [۴۷]، (ج) الگوریتم آب‌پخشان براساس نشانه [۴۰].

همان‌طور که پیش از این ذکر شد، طی فرایند قطعه‌بندی تصویر، غالباً یک حباب به دلیل ناپیوستگی‌ها و پراکندگی‌های نقاط روشن چندگانه، به چند حباب کوچک فلوتاسیون تقسیم

به‌منظور حل مشکل قطعه‌بندی بیش از حد، مهرشاد و مسینایی [۴۰] الگوریتم آب‌پخشان مبتنی بر نشانه را ارائه کردند. در این رویکرد، نقاط حداکثر محلی با یک نشانه جایگزین می‌شود که به‌صورت یک منطقه احاطه شده توسط پیکسل‌های با ارتفاع بالاتر تعریف می‌شود. در سال ۲۰۱۴، جاهدسراوانی و همکاران [۴۷] برای اندازه‌گیری توزیع ابعادی حباب از تصویر کف، این الگوریتم قطعه‌بندی را توسعه دادند. در تبدیل آب‌پخشان نشانه اصلاح شده، علاوه بر اولین نشانه‌های استخراج شده [۴۰]، دو گروه دیگر از نشانه‌ها نیز بررسی می‌شوند و در نهایت، الگوریتم آب‌پخشان به خروجی ترکیبی اعمال می‌شود. نمودار بلوکی الگوریتم توسعه یافته قطعه‌بندی حباب در شکل (۷) نشان داده می‌شود. بدین ترتیب، در تبدیل آب‌پخشان بر پایه نشانه اصلاح شده، سه مجموعه از نشانه‌ها از تصاویر پیش‌پردازش شده استخراج می‌شود و لبه‌های حباب‌ها با استفاده از یک تبدیل آب‌پخشان تعیین می‌گردد.



شکل (۷): نمودار بلوکی الگوریتم قطعه‌بندی حباب اصلاح شده [۴۷]

الگوریتم پیشنهادی با استفاده از تصاویر کف گرفته شده از عملیات فلوتاسیون ناپیوسته کانه سولفید مس در شرایط



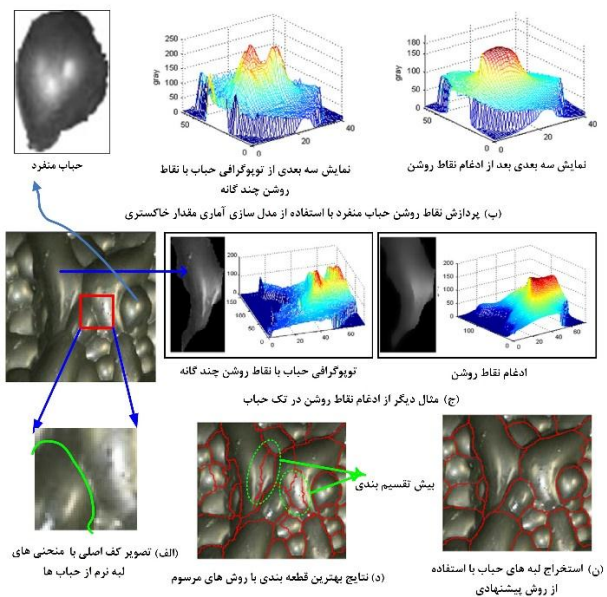
تهیه شده از سلول فلوتاسیون در طول یک دوره با روشنایی و نوع کانی ثابت، اطلاعات نقاط سفید برای طبقه بندی تصاویر کف می تواند استفاده شود [۳۹]. اندازه نقاط سفید با اندازه حبابها متناسب است و تعداد آنها با ابعاد متوسط حباب در تصویر کف، رابطه معکوس دارد.

این الگوریتم به منظور شناسایی نقاط سفید، روش آستانه گذاری دینامیکی [۴۹] را در سراسر تصویر اعمال می کند تا به مقادیر آستانه برای مناطق مختلف دست یابد. پس از آنکه مقادیر آستانه به دست آمد، مقدار آستانه گذاری برای هر پیکسل از تصویر مجدداً محاسبه می شود. در نهایت، تصویر سطح خاکستری به حالت دودویی تبدیل شده و توزیع نقاط سفید برای طبقه بندی تصویر کف به دست می آید. در بیشتر موارد، هرچه اندازه نقاط سفید بزرگ تر باشد، ابعاد حباب بزرگ تر خواهد بود. بنابراین با توجه به این فرضیه، با تعیین توزیع ابعادی نقاط سفید توسط این الگوریتم، توزیع های ابعادی حباب تخمین زده می شوند. این الگوریتم به سرعت می تواند تعداد حبابها، ابعاد متوسط حبابها و توزیع ابعادی حباب را تعیین کند.

وانگ و همکاران [۳۹] برای تخمین اندازه حباب در سه تصویر با اندازه های  $256 \times 256$  پیکسل (شکل ۱۱)، از روش مبتنی بر شناسایی نقاط سفید بر روی سطح حباب استفاده کردند. آنها تصاویر را به سه طبقه تقسیم بندی کردند: اگر اندازه متوسط نقاط سفید کمتر از ۷ و بین ۷ و ۱۵ باشد، تصویر به ترتیب به طبقه ریز و متوسط تعلق دارد و باقی مانده تصاویر در طبقه درشت قرار می گیرند. آنها با تغییر مقدار آستانه، نقاطی را که تعداد پیکسل های آنها کمتر از اندازه مورد نظر است، حذف کرده و توزیع ابعادی حباب را تخمین زدند (جدول ۲).

محرابی و همکاران [۳۶] مقایسه ای را بین روش های قطعه بندی آب پخشان و شناسایی نقاط سفید انجام دادند. طبق نتایج به دست آمده، الگوریتم شناسایی نقاط سفید قادر به تعیین محل دقیق حباب های با شکل و اندازه مختلف بود. به علاوه، در این روش، مشکل قطعه بندی بیش از حد در الگوریتم آب پخشان وجود ندارد.

می گردد که به استخراج نادرست لبه حباب منتهی می شود. برای غلبه بر مشکل بیش قطعه بندی تصویر کف فلوتاسیون، لین و همکاران [۴۸] مدل سازی توزیع آماری مقادیر روشنایی در مناطق محلی تصاویر حباب را به مرحله پیش پردازش ارائه کردند که از آن برای حذف روشنایی های پراکنده و ساده سازی مقدار روشنایی محلی هر حباب استفاده می شود. پس از ادغام روشنایی های چندگانه و تولید یک منطقه هموار برای حباب، تصویر کف برای به دست آوردن منحنی لبه حباب با استفاده از فرایند آب پخشان تقسیم بندی می شود. آنها همچنین به منظور اعتبارسنجی، روش قطعه بندی پیشنهادی تصویر کف را با قطعه بندی آب پخشان و روش قطعه بندی مبتنی بر شناسایی دره-لبه مقایسه کردند. نتایج نشان داده که کارایی روش پیشنهادی از هر دو روش قطعه بندی تصویر مبتنی بر آب پخشان مرسوم و شناسایی دره-لبه دقیق تر است (شکل ۱۰).



شکل (۱۰): تصویری شماتیک از ادغام روشنایی های چندگانه و قطعه بندی تصویر کف با استفاده از روش قطعه بندی پیشنهاد شده توسط لین و همکاران [۴۸].

### ۲.۱.۳. شناسایی نقاط سفید

پدیده قابل توجه در تصویر کف، وجود یک نقطه سفید در سطح هر حباب است که مقدار خاکستری در آن به طور چشمگیری بیش از سایر نقاط موجود در حباب است. درباره تصاویر

### ۳.۱.۳. طیف بافت

مفهوم طیف بافت توسط هی و وانگ در سال ۱۹۹۰ [۵۰] پیشنهاد شد؛ بدین معنی که یک تصویر را می‌توان به وسیله ویژگی‌های آماری واحدهای کوچک به نام واحدهای بافتی توصیف کرد. ویژگی واحد بافت براساس اطلاعات یک پیکسل مشخص و پیکسل‌های هم‌جوار آن محاسبه می‌شود. همان‌طور که در شکل (۱۲) نشان داده می‌شود، واحد بافت یک مربع پیکسلی به اندازه  $3 \times 3$  است که توسط مجموعه‌ای از ۹ عنصر  $\{V_0; V_1; \dots; V_8\}$  بیان می‌شود. که در آن مقدار شدت پیکسل مرکزی و  $i = 1; 2; \dots, 8$  مقدار شدت پیکسل‌های مجاور پیکسل  $i$  را نشان می‌دهند.

ویژگی واحد بافت توسط هشت عنصر  $\{E_1; E_2; \dots; E_8\}$

تعریف می‌شود:

$E_1$	$E_2$	$E_3$
$E_8$		$E_4$
$E_7$	$E_6$	$E_5$

شکل (۱۲): واحد بافت با عناصر ترتیبی در جهت ساعت‌گرد


$$E = \begin{cases} 0 & \text{if } V_0 < V_i \\ 1 & \text{if } V_0 = V_i \\ 0 & \text{if } V_0 > V_i \end{cases}$$

واحد بافت با استفاده از رابطه زیر شاخص‌دهی می‌شود:

$$N_{TU} = \sum_{i=1}^8 E_i * 3^{i-1} \quad (1)$$

که در آن،  $N_{TU}$  نشان‌دهنده شاخص واحد بافت است.

هشت پیکسل مجاور می‌توانند مقادیری کمتر، برابر یا بزرگ‌تر از مقدار پیکسل مرکزی داشته باشند که منجر به تعداد  $3^8$  پیکسل، معادل ۶۵۶۱ ترکیب می‌شود. بنابراین شاخص یک واحد بافت، مقداری بین صفر و ۶۵۶۰ ( $3^8 - 1$ ) خواهد داشت [۴۵].



شکل (۱۱): سه طبقه از تصاویر کف و تصاویر دودویی مربوط به آن‌ها؛ (الف-ج) تصاویر اصلی با ابعاد حباب مختلف و (د-و) تصاویر دودویی [۳۹].

جدول (۲): تحلیل طبقه‌بندی و توزیع اندازه حباب (اندازه نقطه سفید)

مربوط به تصاویر شکل ۱۱ [۳۹]

مورد	تصویر (د)	تصویر (ن)	تصویر (ه)	آستانه
تعداد پیکسل‌ها	۶۹۲۲	۷۶۴۹	۹۳۸۶	۰
تعداد نقاط	۱۳۱۰	۵۸۸	۴۴۱	۰
اندازه میانگین	۵/۲۸	۱۳	۲۱/۲۸	۰
تعداد پیکسل‌ها	۵۰۰۶	۷۱۳۵	۸۸۶۶	۵
تعداد نقاط	۳۸۴	۳۰۴	۲۲۸	۵
اندازه میانگین	۱۳/۰۴	۲۳/۴۷	۳۸/۸۹	۵
...	...	...	...	...
تعداد پیکسل‌ها	۶۲۹	۴۹۷	۲۵۲۳	۱۲۰
تعداد نقاط	۴	۳	۱۳	۱۲۰
اندازه میانگین	۱۵۷/۲۵	۱۶۵/۷	۱۹۴/۱	۱۲۰
تعداد پیکسل‌ها	۲۰۰	۰	۱۳۵۱	۲۰۰
تعداد نقاط	۱	۰	۵	۲۰۰
اندازه میانگین	۲۰۰	۰	۲۷۰/۲	۲۰۰

لین و همکاران [۴۵] اندازه حباب تصویر مربوط به شکل (۶) را (که اعمال روش‌های سنتی تعیین لبه و قطعه‌بندی آب‌پخش‌شان، کارایی نامطلوبی را در پی داشت)، با رویکرد مبتنی بر تصویر دودویی تخمین زدند. آن‌ها ثابت کردند که رویکرد مبتنی بر تصویر دودویی، ویژگی‌های حباب‌های کف را به صورت منطقی تخمین می‌زند.

که در آن،  $I_C$  شدت پیکسل مرکزی و  $\bar{I}$  شدت متوسط تصویر است. محدوده جدید برای مقدار واحد بافت مابین صفر و ۱۳۱۶۱ قرار می‌گیرد. به علاوه، مقدار واحدهای بافت واقع در بالای سطح حباب، بیش از مقدار واحد زمینه است. بنابراین با اطمینان بیشتری می‌توان ابعاد حباب را تخمین زد.

به هنگام بالا بودن تعداد حباب‌ها، رابطه اصلی تخمین اندازه حباب یعنی معادله (۳)، به بیان حباب‌های «بزرگ» گرایش دارد. بنابراین، باید تعداد حباب‌ها ( $N_B$ ) (برای تخمین اندازه حباب با رویکرد طیف بافت مدنظر قرار گیرد. معادله اصلاح شده به صورت زیر نوشته می‌شود:

$$B_S = \sqrt{\sum_{i=3281}^{6560} h_i * (1 - \frac{N_B^\alpha}{NN})} \quad (4)$$

که در آن،  $\alpha$  یک عامل نمایی و  $NN$  یک عامل مقیاس گذاری است.

بر اساس نتایج به دست آمده، رویکرد طیف بافت اصلاح شده به درستی تغییر ابعاد حباب را به هنگام اعمال به تصاویر کف تعیین می‌کند. با وجود اینکه رویکرد طیف بافت اصلاح شده محاسبه ابعاد حباب را بهبود می‌بخشد، درک آن برای دستیابی به توزیع ابعاد حباب ساده نیست.

### ۵.۱.۳. همگنی

همان‌طور که پیش از این ذکر شد، به طور کلی قبل از دستیابی به توزیع ابعادی حباب، باید مراحل پیش‌پردازش و قطعه‌بندی تصویر انجام شوند. با وجود این، گاهی حتی پس از اعمال بهبود کنتراست و فیلترینگ بر تصویر، قطعه‌بندی برخی تصاویر کف نظیر کف‌های فلوتاسیون زغال (شکل ۱۳) بسیار دشوار است [۴۴]. درحقیقت، در بسیاری از تصاویر کف می‌توان اشکال نامنظم با هر دو رنگ سفید و سیاه را در سطح حباب مشاهده کرد. حتی بخش‌هایی از سطح حباب، شفاف و حباب‌های زیرین قابل مشاهده‌اند. بنابراین، از ویژگی‌های بافت (همگنی) می‌توان برای بیان ابعاد حباب به صورت یک روش آماری استفاده کرد.

واحد بافت، ویژگی‌های محلی یک پیکسل معین، به خصوص روابط سطح خاکستری نسبی بین پیکسل مرکزی و پیکسل‌های مجاور را توصیف می‌کند. آماره‌های مربوط به تمام واحدها، کل تصویر را توصیف می‌کنند. بنابراین، طیف بافت به صورت هیستوگرام تمام واحدهای بافت یعنی توزیع تمام واحدهای بافت تعریف می‌شود. انگوین و سورنتون [۴۱] کاربرد طیف بافت را در طبقه‌بندی تصاویر کف فلوتاسیون گزارش کرده‌اند.

به دلیل انعکاس نور، پیکسل‌های واقع در مرکز حباب‌های کف طبیعتاً از مقادیر شدت بزرگ‌تری نسبت به پیکسل‌های مجاور برخوردارند. براساس معادله (۱)، شاخص یک واحد بافت احتمالاً مقدار بزرگی است. در نتیجه، می‌توان یک مقدار قابل درک را برای ابعاد حباب ( $B_S$ ) به صورت زیر تعریف کرد:

$$B_S = \sqrt{\sum_{i=3281}^{6560} h_i} \quad (2)$$

که در آن،  $h_i$  تعداد واحدهای بافت با مقدار برابر با  $i$  است [۴۱]. کاربرد تحلیل طیف بافت برای ارزیابی سطح کف، توسط هولسام و انگوین [۱۸] انجام پذیرفته و در نرم‌افزار JK FrothCam™ به کار گرفته شده است.


### ۴.۱.۳. رویکرد طیف بافت پیشرفته

لین و همکاران [۴۵] در سال ۲۰۰۸ نشان دادند که رویکرد طیف بافت قادر به ارائه تخمین قابل اطمینان از ابعاد حباب نیست. بنابراین، آن‌ها یک رویکرد طیف بافت اصلاح شده را پیشنهاد و ارائه کردند.


باتوجه به اینکه یک واحد بافت از ۹ پیکسل با شدت برابر تشکیل می‌شود، مقدار واحد بافت براساس معادله (۲) برابر با ۳۲۸۰ است و هیچ اهمیتی ندارد که این پیکسل در مرکز حباب (با بالاترین شدت) قرار داشته باشد یا در زمینه آن (با کمترین شدت). بنابراین معادله (۲) به صورت زیر اصلاح می‌شود [۴۵]:

$$NTU \left\{ \begin{array}{l} \sum_{i=1}^8 E_i * 3^{i-1} \text{ if } I_C \leq \bar{I} \\ 6581 + \sum_{i=1}^8 E_i * 3^{i-1} \text{ if } I_C > \bar{I} \end{array} \right\} \quad (3)$$

شکل ۱۳) نشان می‌دهد. مشاهده می‌شود که ابعاد حباب در طول زمان عملیات فلوتاسیون افزایش می‌یابد. این موضوع را می‌توان بدین صورت توضیح داد که غلظت کف‌ساز با سرریز شدن کانی‌های قابل فلوتاسیون کاهش می‌یابد و ترکیدن و ادغام حباب‌ها متناوباً رخ می‌دهد. مشاهده می‌شود که در مقدار کف‌ساز  $206 \text{ g/t}$  (شکل ۱۴ ب)، اندازه حباب در طول زمان ۵۰ ثانیه، در ابعاد بسیار کوچک باقی می‌ماند. کف‌ساز باقی‌مانده ناشی از غلظت بالای آن، منجر به حفظ حباب‌ها در ابعاد ریز شده و سرریز پیوسته کف به همراه آب و ذرات دنباله‌روی شده را در پی دارد که به بالاترین غلظت محتوای خاکستر نسبت داده می‌شود.



شکل (۱۳): تصاویر عملیاتی از کف فلوتاسیون زغال به دست آمده تحت شرایط  $82 \text{ g/t}$  کف‌ساز (تصاویر گرفته شده به صورت تصادفی از زمان‌های مختلف) [۴۴]



شکل (۱۴): همگنی بافت به صورت تابعی از افست در زمان‌های فلوتاسیون مختلف الف.  $52 \text{ g/t}$  و ب.  $206 \text{ g/t}$  [۴۴]


### ۳.۱.۶. شناسایی لبه-دره

عملیات شناسایی لبه-دره برای تعیین لبه‌های بارز از یک تصویر توسط محاسبه گرادیان و برای تصویر استفاده می‌شود. عمل‌گر رابرت (حساس به نویز)، سوبل و پرویت، آشکارسازهای مرتبه اول‌اند که برای شناسایی خودکار لبه

همگنی یکی از آماره‌های به دست آمده از ماتریس هم‌رخداد مقیاس خاکستری (GLCM) است. مقدار همگنی بین صفر و یک متغیر است. همگنی برابر با ۱ به GLCM قطری تعلق دارد و بیان‌کننده همگنی شدید تصویر است. به طور کلی، همگنی با ابعاد حباب افزایش می‌یابد.

تان و همکاران [۴۴] در سال ۲۰۱۶، تصاویر تصادفی را در زمان‌های مختلف فلوتاسیون زغال و با مقدار کف‌ساز  $82 \text{ g/t}$  و  $206 \text{ g/t}$  تهیه کردند. میزان همگنی بافت به صورت تابعی از افست (offset) در زمان‌های فلوتاسیون مختلف در شکل (۱۴) نشان داده شده است. افست‌ها در جهت افقی به صورت [zeros (50,1) (1:50)] و به صورت افست‌هایی از [۰,۱]، [۰,۲] تا [۰,۵۰] تعریف می‌شوند. فواصل از ۱ تا ۵۰ پیکسل متغیر است که متناظر با محدوده ابعادی حباب در تصویر فلوتاسیون در نظر گرفته شده است.

مقدار بالای همگنی به دست آمده در افست بزرگ‌تر، می‌تواند حباب‌های بزرگ‌تری را در سطح کف نشان دهد. مقدار افست می‌تواند سنجشی از اندازه حباب باشد در حالی که همگنی، میزان وجود سطوح خاکستری یکسان را در فواصل مختلف از افست نشان می‌دهد. شکل (۱۴ الف) به خوبی توزیع ابعادی حباب را در تصاویر کف زغال (ارائه شده در



شکل (۱۵): شناسایی لبه: شش تصویر (الف-و) به ترتیب شناسایی لبه با سوبل، روبرت، لاپلاسین، پرویت، کنی و کنی آستانه گذاری شده با آستانه ۳۰ است (ی) تصویر اصلی [۳۹]

وانگ و همکاران [۳۹] از لبه‌های نقاط سفید صرف‌نظر کردند و در نهایت، یک الگوریتم شناسایی لبه-دره جدید را توسعه دادند. با شناسایی لبه-دره، بر روی تشخیص لبه-دره‌های موجود در بین حباب‌ها تمرکز می‌شود و از لبه‌های بافت در روی یک حباب صرف‌نظر می‌گردد. تصاویر به‌منظور حذف نویزها از طریق فیلتر، پیش‌پردازش می‌شوند و سپس پیکسل‌های تصویر، از طریق بررسی قرار گرفتن آن‌ها در پایین‌ترین نقاط در دره‌ها در جهات مشخص، به‌عنوان لبه‌های کاندید احتمالی ارزیابی می‌شوند. به‌منظور حصول اطمینان از عدم وجود هیچ فاصله‌ای بین لبه-دره‌ها، روش پاک‌سازی انجام می‌شود. نویسندگان به این نتیجه رسیده‌اند که این رویکرد به‌طور چشمگیری قابل اطمینان‌تر است و سرعت آن در مقایسه با روش‌های قبلی برای قطعه‌بندی تصاویر کف بیشتر است [۲۱].

#### ۴. همبستگی بین پارامترهای متالورژی و اندازه حباب

تخمین کارایی متالورژیکی از ویژگی‌های بصری کف و کنترل

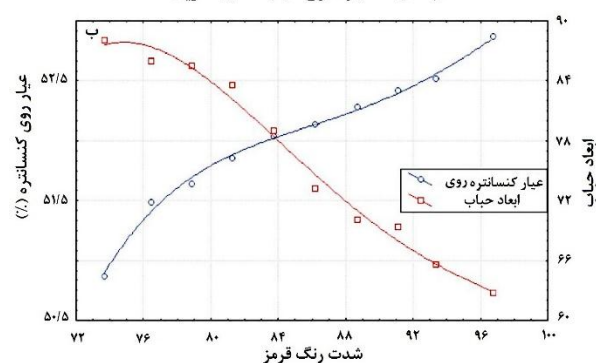

بسیار سودمند هستند. از آشکارساز کنی (Cany) به‌دلیل مقامت در برابر نویز و قابلیت شناسایی نقاط لبه واقعی با کمترین خطا، به‌طور گسترده در زمینه بینایی ماشین استفاده می‌شود [۵۱].

کیپریانو و همکاران [۳۸] یک سیستم بینایی ماشینی تحت عنوان ACEFLOT را گزارش دادند که ابعاد حباب را براساس روش شناسایی لبه تخمین می‌زند. مرکز و لبه هر حباب از طریق عمل‌گرهای مورفولوژیکی گرادیان شدت بالا-پایین مانند باز (Opening) و بسته شدن (Closing) شناسایی می‌شود. وانگ و همکاران [۴۲] دریافتند که گرادیان شدت پیکسل‌های بین حباب‌ها در تصاویر کف برای شناسایی قابل‌اعتماد لبه، از طریق توابع شناسایی کلاسیک، بسیار کوچک‌اند. به‌علاوه، گرادیان‌های شدت پیکسل‌ها در نقاط سفید یا آینه‌ای در بالای حباب‌ها بسیار بزرگ است که منجر به عدم توانایی روش‌های کلاسیک مانند روش‌های توصیف‌شده توسط کنی [۵۲]، فیو [۵۳] و پال [۵۴] می‌شود. در شکل (۱۵ الف-و)، نتایج شناسایی لبه با به‌کارگیری الگوریتم‌های فوق آورده شده‌اند [۳۹].

در شکل (۱۵)، نتایج شناسایی لبه لاپلاسین ضعیف ست و تعداد ناچیزی از لبه‌های شفاف شناسایی می‌شوند. نتایج به‌کارگیری شناسایی لبه کنی، پرویت، روبرت و سوبل بعضی از بخش‌های لبه‌های تعدادی از حباب‌ها را ارائه می‌دهد، اما لبه‌های حباب از لبه‌های نقاط سفید بسیار ضعیف‌ترند. شکل (۱۵ و) نشان می‌دهد زمانی که شناسایی لبه کنی آستانه‌گذاری شده با یک مقدار آستانه برابر ۳۰ به‌کار گرفته شود (که اکثر نقاط سفید شناسایی می‌شوند)، اکثر لبه‌های حباب ناپدید می‌شوند. نتیجه اینکه این الگوریتم‌ها به‌طور موفقیت‌آمیزی نمی‌توانند برای شناسایی حباب‌های بیشتر یا قطعه‌بندی تصویر به‌کار گرفته شوند؛ زیرا نقاط سفید به‌شدت روی نتایج شناسایی لبه تأثیر می‌گذارند و همچنین تغییرات مقدار خاکستری در لبه‌های بین حباب‌ها زمانی که الگوریتم‌های شناسایی لبه مذکور به‌کار گرفته می‌شود، برجسته نیست.

کارتینن و همکاران [۱۹] ثابت کردند که متغیر بار حباب (میزان شفافیت) و شدت رنگ قرمز بهترین شاخص برای کارایی فلوتاسیون روی است. شکل (۱۷ الف) بازیابی را در برابر منحنی بار حباب (شفافیت) به همراه متوسط‌های اندازه حباب نشان می‌دهد. نتایج نشان می‌دهد که اندازه حباب ریز حباب با عیار بالای کنسانتره و بازیابی در ارتباط است.



جاهد سراوانی و همکاران [۵۴] برای اهداف کنترلی، همبستگی بالایی را میان ویژگی‌های بصری کف، به‌ویژه ابعاد حباب و عوامل کارایی فلوتاسیون تعیین کردند. شکل (۱۸) همبستگی بین ابعاد حباب، بازیابی و عیار مس کنسانتره را نشان می‌دهد. نتایج حاکی از آن است که حباب‌های ریزتر با تحرک بیشتر، بازیابی مس بالاتری را به دنبال دارد. همچنین منجر به افزایش جرم ذرات و آب راه یافته به کنسانتره و کاهش عیار کنسانتره می‌شود. این موضوع با مشاهدات صورت گرفته از واحد عملیات مطابقت دارد [۱۸].



شکل (۱۷): ارتباط بازیابی (الف) و عیار (ب) روی کنسانتره با ابعاد حباب در مقابل شفافیت و رنگ قرمز تصویر [۱۹]

فرایند از طریق تغییر متغیرهای عملیاتی، هدف نهایی از به‌کارگیری یک سیستم کنترل مبتنی بر ماشین بینایی است [۱۸] و [۱۹]. کاربران باتجربه واحد فلوتاسیون، از اندازه حباب کف برای یافتن مقدار بهینه شرایط عملیاتی مانند میزان افزودن مواد شیمیایی برای نیل به اهداف متالورژیکی موردنظر استفاده می‌کنند.

محرابی و همکاران [۳۶] رابطه بین اندازه حباب در کف و کارایی متالورژیکی در یک واحد فلوتاسیون آهن-فسفر را گزارش دادند که نتایج آن در شکل (۱۶) مشاهده می‌شود. نتایج نشان داد که همبستگی بالایی میان اندازه متوسط حباب، تعداد حباب‌ها در کف و پارامترهای متالورژیکی وجود دارد. همان‌گونه که انتظار می‌رود، بازیابی فسفر مستقیماً با تعداد حباب‌ها و به‌طور معکوس با اندازه متوسط حباب‌ها متناسب است.



شکل (۱۶): همبستگی بین پارامترهای متالورژی و اندازه حباب [۳۶]

روشنایی در مناطق محلی تصاویر حباب به منظور ادغام روشنایی‌های چندگانه پیشنهاد شده است. با وجود این، یکپارچه‌سازی این عملیات پیش‌پردازش با سیستم کنترل زمان واقعی، از منظر محاسباتی بسیار دشوار است.

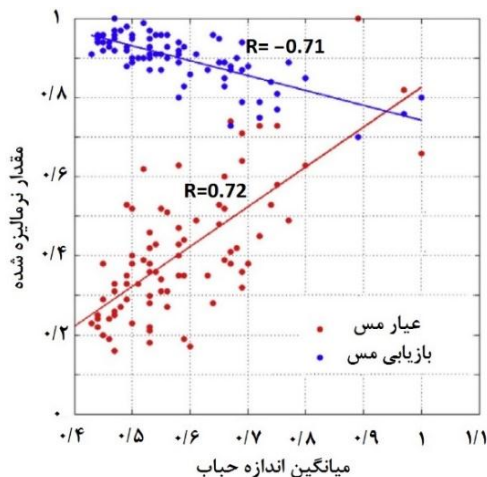
۳. در تصاویر کف با جزئیات بسیار زیاد (حباب‌های ریز) الگوریتم شناسایی نقاط سفید در سطح حباب، قادر به تخمین تعداد و ابعاد حباب به صورت منطقی بود. در این روش، مشکل قطعه‌بندی بیش از حد در الگوریتم آب‌پخشان وجود ندارد، اما اندازه‌گیری دقیق ابعاد حباب ممکن نیست.

۴. رویکرد طیف بافت به درستی ابعاد حباب را به‌هنگام اعمال به تصاویر کف تعیین می‌کند، اما درک آن برای دستیابی به توزیع ابعاد حباب بسیار مشکل است.

۵. در بسیاری از تصاویر کف، اشکال نامنظم با هر دو رنگ سفید و سیاه در سطح حباب مشاهده می‌شود که فرایند قطعه‌بندی را بسیار دشوار و غیرممکن می‌کند. بنابراین، از ویژگی‌های آماری بافت (همگنی) می‌توان برای بیان ابعاد حباب استفاده کرد. مقادیر بالای همگنی نشان‌دهنده حباب‌های بزرگ‌تر در سطح کف است.

۶. با گرفتن تصاویر با وضوح بالا می‌توان تا حدی از مشکلات موجود در مراحل پیش‌پردازش و آنالیز تصویر کاست. اما این عمل نیازمند هزینه‌های محاسباتی است که با کاربرد بلادرنگ این سیستم‌ها در تضاد است. مشخصاً این حوزه‌ای است که از افزایش قابل پیش‌بینی قدرت پردازش رایانه‌ها در آینده بهره خواهد برد.

۷. در هر سلول فلوتاسیون، روابط معناداری میان ابعاد حباب کف، متغیرهای عملیاتی و نرخ بازیابی و عیار کنسانتره وجود دارد. این موضوع باید به شناسایی نقاط بهینه متغیرهای عملیاتی، در کنترل خودکار فرایند منتهی شود.



شکل (۱۸): همبستگی میانگین ابعاد حباب با عیار و بازیابی مس [۵۴]

## ۵. نتیجه گیری

در این مقاله، کاربرد سیستم‌های پردازش تصویر در فرایندهای فلوتاسیون، با تمرکز بر تخمین اندازه حباب کف به‌عنوان مهم‌ترین شاخص ارزیابی شرایط عملیاتی ارائه شده است. از آنجایی که ظاهر تصاویر کف گرفته‌شده از عملیات فلوتاسیون کانه‌های مختلف دارای جزئیات و ویژگی‌های بسیار متفاوتی هستند، از یک روش واحد پردازش تصویر برای اندازه‌گیری‌های کمی ابعاد حباب نمی‌توان استفاده کرد. بدین منظور روش‌های مختلف استخراج داده‌ها از تصاویر کف برای تخمین ابعاد حباب‌ها به‌همراه مزایا و محدودیت‌های آن‌ها بررسی شد. نتایج حاصل از این مطالعه به شرح زیر است:

۱. در زمان اعمال الگوریتم آب‌پخشان به تصاویر با جزئیات بسیار زیاد، قطعه‌بندی بیش از حد تصویر (احتمال تقسیم حباب‌های بزرگ فلوتاسیون به حباب‌های کوچک‌تر) ناشی از نقاط روشن چندگانه بر روی حباب‌ها، یک مشکل عمده است.
۲. به‌منظور حل مشکل قطعه‌بندی بیش از حد، الگوریتم آب‌پخشان مبتنی بر نشانه، آب‌پخشان سلسله‌مراتبی و ترکیب آن با شبکه عصبی، استفاده از مدل‌سازی توزیع آماری مقادیر

## مراجع

[1] Wills, B.A., Napier-Munn, T.J., 2006. Mineral Processing Technology. Elsevier Science & Technology Books.

[2] Nakhaei, F., Mosavi, M.R., Sam, Y., Vaghei., 2012. "Recovery and grade accurate prediction of pilot plant flotation column concentrate: neural network

- and statistical techniques". *International Journal of Mineral Processing* 110–111, 140–154.
- [3] Nakhaei, F., Irannajad, M., 2013. "Comparison between neural networks and multiple regression methods in metallurgical performance modeling of flotation column". *Physicochemical Problems Mineral Process.* 49 (1), 255–266.
- [4] Nakhaei, F., Irannajad, M., 2013. "Forecasting grade and recovery of flotation column concentrate using radial basis function and layer recurrent neural networks". *AWERProcedia Inf. Technol. Comput. Sci.* 04, 454–473.
- [5] Haiyang, Z., Yali, K., Guanghui, W., Li, J., 2014. "Soft sensor model for coal slurry ash content based on image grey characteristics". *Int. J. Coal Prep. Util.* 34 (1), 24–37
- [6] Jovanovic, I., Miljanovic, I., Jovanovic, T., 2015. "Soft computing-based modeling of flotation processes – A review". *Minerals Engineering* 84, 34–63
- [7] Bonifazi, G., Massacci, P., Meloni, A., 2002. "3D froth surface rendering and analysis technique to characterize flotation processes", *Int. J. Miner. Process.* 64, 153–161.
- [8] Shean, B. J., Cilliers, J. J., 2011. "A review of froth flotation control". *International Journal of Mineral Processing*, 100 (3-4):57-71..
- [9] Bonifazi, G., Serranti, S., Volpe, F., Zuco, R., 2001. "Characterization of flotation froth colour and structure by machine vision". *Comput. Geosci.* 27 (9), 1111–1117.
- [10] Yang, C., Xu, C., Mu, X., Zhou, K., 2009. "Bubble size estimation using interfacial morphological information for mineral flotation process monitoring". *Trans. Nonferrous Met. Soc. China* 19, 694–699.
- [11] Xu, C., Gui, W., Yang, C., Zhu, H., Lin, Y., Shi, C., 2012. "Flotation process fault detection using output PDF of bubble size distribution". *Minerals Engineering* 26, 5–12.
- [12] Moolman, D.W., Aldrich, C., Schmitz, G.P.J., Van Deventer, J.S.J., 1996. "The interrelationship between surface froth characteristics and industrial flotation performance". *Minerals Engineering* 9 (8), 837–854.
- [13] Bergh, L. G., and Yianatos, J., 2003. "Flotation Column Automation: State of the Art". *Journal of Control Engineering Practice*, 11(1), 67-72.
- [14] Haavisto, O., Kaartinen, J., 2009. "Multichannel reflectance spectral assaying of zinc and copper flotation slurries". *International Journal of Mineral Processing* 93 (2), 187–193.
- [15] Del Villar, R., Desbiens, A., Maldonado, M. and Bouchard, J., 2010. *Automatic Control of Flotation Columns*. In: *Advanced Control and Supervision of Mineral Processing Plants*, edited by D. Sbarbaro and R. Del Villar, pp. 249–286. Springer.
- [16] Moolman, D.M., Aldrich, C., Van Deventer, J.S.J., 1995. "The interpretation of flotation froth surfaces by using digital image analysis and neural networks". *Chem. Eng. Sci.* 50, 3501–3513.
- [17] Moolman, D.W., Eksteen, J.J., Aldrich, C., Van Deventer, J.S.J., 1996. "The significance of flotation froth appearance for machine vision control". *Int. J. Miner. Process.* 48 (3–4), 135–158
- [18] Holtham, P.N., Nguyen, L.K., 2002. "On-line analysis of froth surface in coal and mineral flotation using JK FrothCam". *Int. J. Miner. Process.* 64, 163–180.
- [19] Kaartinen, J., Hatonen, J., Hyotyniemi, H., Miettunen, J., 2006. "Machine vision based control of zinc flotation—a case study". *Control. Eng. Pract.* 14, 1455–1466.
- [20] Vanegas, C., Holtham, P., 2008. "On-line froth acoustic emission measurements in industrial sites". *Miner. Eng.* 21, 883–888.
- [21] Aldrich, C., Marais, C., Shean, B.J., Cilliers, J.J., 2010. "Online monitoring and control of froth flotation systems with machine vision: a review". *International Journal of Mineral Processing* 96, 1–13.
- [22] Morar, S.H., Harris, M.C., Bradshaw, D.J., 2012. "The use of machine vision to predict flotation performance". *Miner. Eng.* 36–38, 31–36..
- [23] Sadr-Kazemi, N., Cilliers, J.J., 1997. "An image processing algorithm for measurement of flotation froth bubble size and shape distributions". *Minerals Engineering* 10 (10), 1075–1083.
- [24] Oestreich, J.M., Tolley, W.K., Rice, D.A., 1995. "Development of a color sensor system to measure mineral compositions". *Minerals Engineering* 8 (1–2), 31–39.
- [25] Brosnan, T., & Sun, D. W., 2004. "Improving quality inspection of food products by computer vision e A review". *Journal of Food Engineering*, 61, 3-16.
- [26] Zuech, N., 1988. "Applying machine vision". New York, USA: John Wiley & Sons, Inc.
- [27] Vithu, P., Tech, M., Moses, J. A., Tech, M., 2016. "Machine vision system for food grain quality



- evaluation: A review", *Trends in Food Science & Technology* 56, 13-20.
- [28] Hornberg, A., 2007. *Handbook of machine vision*. Germany: John Wiley & Sons..
- [29] Singh, V., Mohan Rao, S., 2005. "Application of image processing and radial basis neural network techniques for ore sorting and ore classification", *Minerals Engineering* 18, 1412-1420
- [30] Prats-Montalbán, J.M. de Juan, A., Ferrer, A., 2011. "Multivariate image analysis: A review with applications", *Chemometrics and Intelligent Laboratory Systems* 107, 1-23.
- [31] Tessier, J., Duchesne, C., Bartolacci, G., 2007. "A machine vision approach to on-line estimation of run-of-mine ore composition on conveyor belts", *Minerals Engineering* 20, 1129-1144
- [32] Banford, A.W., Aktas, Z., Woodburn, E.T., 1998. "Interpretation of the effect of froth structure on the performance of froth flotation using image analysis". *Powder Technology* 98 (1), 61-73.
- [33] De Jager, G., Hatfield, D.P., Bradshaw, D.J., Francis, J.J., Morar, S.H., 2004. A method and a control system for extracting valuable minerals from mined ore, "SmartFroth", Adams and Adams Patent Attorneys, Pretoria, A and A REF: v16148 (1-9), Provisional patent lodged 24 Feb 2004.
- [34] Moolman, D.W., Aldrich, C., Van Deventer, J.S.J., Stange, W.W., 1994. "Digital image processing as a tool for on-line monitoring of froth in flotation plants". *Minerals Engineering*, 7 (9), 1149-1164
- [35] Wang, Z., Li, H., Zhu, Y., Xu T.F., 2016. "Review of Plant Identification Based on Image Processing". *Arch Comput at Methods Eng*.
- [36] Mehrabi, A., Mehrshad, N., Massinaei, M., 2014. "Machine vision based monitoring of an industrial flotation cell in an iron flotation plant". *International Journal of Mineral Processing* 133, 60-66.
- [37] Woodburn, E.T., Austin, L.G. and Stockton, J.B., 1994. "A froth based flotation kinetic model". *Trans. IChemE*, 72(A)(March): 2 1 I-226.
- [38] Cipriano, A., Guarini, M., Vidal, R., Soto, A., Sepulveda, C., Mery, D., Briseno, H., 1998. "A real time visual sensor for supervision of flotation cells". *Miner. Eng.* 11 (6), 489-499.
- [39] Wang, W., Bergholm, F., Yang, B., 2003. "Froth delineation based on image classification". *Miner. Eng.* 16, 1183-1192.
- [40] Mehrshad, N., Massinaei, M., 2011. "New image processing algorithm for measurement of bubble size distribution from flotation froth images". *Miner. Metall. Process. J.* 28 (3), 146-150.
- [41] Nguyen, K.K., Thornton, A.J., 1995. "The application of texture-based image analysis techniques in froth flotation". *Conference Proceedings DICTA-95 Digital Image Computing: Techniques and Applications*. Australian Pattern Recognition Society.
- [42] Liu, J.J., MacGregor, J.F., Duchesne, C., Bartolacci, G., 2005. "Flotation froth monitoring using multiresolutional multivariate image analysis". *Minerals Engineering* 18, 65-76
- [43] Wang, W., Li, L., 2005. "Image analysis and computer vision for mineral froth". *IEEE International Conference on Mechatronics and Automation, ICMA 2005*, 1790-1795.
- [44] Tan, J., Liang, L., Peng, Y., Xie, G. 2016. "The concentrate ash content analysis of coal flotation based on froth images". *Minerals Engineering* 92, 9-20
- [45] Lin, B., Recke, B., Knudsen, J.K.H., Jorgensen, S.B., 2008. "Bubble size estimation for flotation processes". *Miner. Eng.* 21, 539-548.
- [46] Runge, K., McMaster, J., Wortley, M., Rosa, D.L., Guyot, O., 2007. "A correlation between visiofroth™ measurements and the performance of a flotation cell". In *Ninth Mill Operators' Conference* (pp. 19-21). Fremantle, Western Australia.
- [47] Jahedsaravani, A., Marhaban, M.H., Massinaei, M., Saripan, M.I., Mehrshad, N., 2014. "Development of a new algorithm for segmentation of flotation froth images". *Minerals & Metallurgical Processing*, Vol. 31, No. 1, pp. 66-72.
- [48] Liu, J., Gui, W., Tang, Z., Yang, C., Zhu, J., Li, J. 2013. "Recognition of the operational statuses of reagent addition using dynamic bubble size distribution in copper flotation process". *Minerals Engineering*, 45, 128-141.
- [49] Otsu, N., 1979. "A threshold selection method from gray-level histogram". *IEEE Trans. Syst. Man Cybernet SMC-9*, 62-66.
- [50] Dutta, S., Pal, S.K., Mukhopadhyay, S., Sen, R., 2013. "Application of digital image processing in tool condition monitoring: A review", *CIRP Journal of Manufacturing Science and Technology* 6, 212-232.
- [51] He, D.C., Wang, L., 1990. "Texture feature extraction from texture spectrum". *IEEE Transactions on Geosciences and Remote Sensing*

28 (4), 509–512.

- [52] Canny, J.F., 1986. "A computational approach to edge detection". *IEEE Transactions on Pattern Analysis and Machine Intelligence* 8, 679–698.
- [53] Fu, K.S., Mu, J.K., 1981. "A survey on image segmentation". *Pattern Recognition* 13, 3–16.
- [54] Pal, N.R., Pal, S.K., 1993. "A review of image segmentation techniques". *Pattern Recognition* 26 (9), 1277–1294.