

واترمارکینگ و فقی تصاویر دیجیتال مبتنی بر یادگیری ماشینی

پیمان نفیسی فرد^۱، ولی درهمی^۲ و علی محمد لطیف^۳

۱- کارشناس ارشد، دانشکده مهندسی برق و کامپیوتر- دانشگاه یزد - یزد - ایران

payman_nafisifard@yahoo.com

۲- استادیار، دانشکده مهندسی برق و کامپیوتر- دانشگاه یزد - یزد - ایران

vderhami@yazduni.ac.ir

۳- استادیار، دانشکده مهندسی برق و کامپیوتر- دانشگاه یزد - یزد - ایران

alatif@yazduni.ac.ir

چکیده: با استفاده گسترده از اینترنت و توسعه صنعت رایانه، حفاظت از حق چاپ انتشارات دیجیتالی به موضوعی بسیار جدی مبدل شده است. واترمارکینگ دیجیتالی شیوه مناسبی برای حل این مشکل است. در این مقاله یک روش واترمارکینگ و فقی در حوزه تبدیل کسینوسی گسسته (DCT) برای تصاویر دیجیتال ارائه می‌گردد. در این روش، تصویر میزبان به بلوک‌های بدون همپوشانی ۸×۸ تقسیم می‌شود و بیت‌های واترمارک در ضرایب DCT این بلوک‌ها جاسازی می‌شوند. برای افزایش امنیت روش، مکان‌های جاسازی به صورت تصادفی انتخاب می‌گردند. بلوک‌های منتخب برای جاسازی واترمارک بر اساس ویژگی‌هایی نظیر بافت، روشنایی و نزدیکی به لبه‌ها به شش کلاس مختلف طبقه‌بندی می‌شوند. در این تحقیق، از ماشین بردار پشتیبان (SVM) برای شبیه‌سازی سیستم بینایی انسان (HVS) جهت طبقه‌بندی بلوک‌ها استفاده می‌شود. سپس برای جاسازی و فقی واترمارک، از الگوریتم ژنتیک برای تعیین ضرایب قوت واترمارک بهینه در کلاس‌های مختلف استفاده می‌شود. نتایج پیاده‌سازی نشان می‌دهد که روش ارائه شده شفافیت بالا و مقاومت بسیار خوبی در برابر حمله‌های مختلف دارد.

واژه‌های کلیدی: واترمارکینگ و فقی تصاویر دیجیتال، سیستم بینایی انسان، ماشین بردار پشتیبان، الگوریتم ژنتیک

۱- مقدمه

سیگنال دیجیتالی محرمانه، در یک سند دیجیتالی پنهان می‌شود و در تمام طول عمر سند به آن متصل است. سند دیجیتالی می‌تواند یک تصویر، ویدیو، صوت یا متن باشد که در این مقاله، واترمارکینگ تصاویر دیجیتال مورد بحث است. واترمارکینگ کاربردهای گوناگونی دارد که مهمترین کاربرد آن حفاظت از حق نشر و یا اثبات حق مالکیت است. در روش‌های واترمارکینگ، مجموعه‌ای از ملزومات وجود دارد که باید مورد توجه قرار گیرند. از مهمترین ملزومات آن می‌توان به شفافیت، مقاومت، امنیت و میزان ظرفیت واترمارک اشاره کرد. در این میان، شفافیت و مقاومت واترمارکینگ از اهمیت بیشتری برخوردارند. منظور از شفافیت، غیر قابل مشاهده بودن اطلاعات نهفته شده در

امروزه با پیشرفت سریع تکنولوژی اطلاعات دیجیتالی و گسترش استفاده از شبکه‌های رایانه‌ای و اینترنت، دسترسی به اطلاعات دیجیتال و کپی برداری از آن‌ها به آسانی امکان پذیر است، بنابراین، مسأله حفاظت از داده‌ها در مقابل کپی برداری و توزیع غیرقانونی اسناد و جعل از اهمیت بالایی برخوردار است. هم‌اکنون مؤثرترین روش، استفاده از تکنیک واترمارکینگ است. در این روش یک

* تاریخ ارسال مقاله: ۱۳۹۰/۳/۳

تاریخ پذیرش مقاله: ۱۳۹۱/۶/۱۲

نام نویسنده مسؤول: علی محمد لطیف

نشانی نویسنده مسؤول: ایران - یزد - صفائیه - دانشگاه یزد -

دانشکده مهندسی برق و کامپیوتر

کننده فازی و سیستم بینایی انسان ارائه شده است. در [۱۰] نیز روشی جدید مبتنی بر یادگیری تقویتی^۴ (RL)، برای تعیین وفقی ضریب قوت واترمارک ارائه شده است.

یکی از تکنیک‌های یادگیری ماشینی که اخیراً در بحث واترمارکینگ مطرح شده است، ماشین بردار پشتیبان^۵ (SVM) است. SVM، یک طبقه‌بندی کننده دودویی است که با تغییراتی می‌تواند به عنوان یک تخمین زنده استفاده شود که به آن رگرسیون بردار پشتیبان^۶ (SVR) گویند. در اکثر روش‌های واترمارکینگ مبتنی بر بردارهای پشتیبان از SVR برای بررسی روابط موجود بین پیکسل‌ها در حوزه مکان به منظور درج و استخراج واترمارک استفاده می‌گردد. برای مثال، در [۱۱،۱۲] پس از انتخاب تعدادی نقاط در تصویر میزبان، SVR، رابطه بین آن‌ها و نقاط همسایه را بررسی می‌کند و سپس یک مدل SVR آموزش دیده حاصل می‌شود. برای عمل درج واترمارک، پس از انتخاب نقاط جاسازی، از رابطه بین آن نقاط و خروجی SVR آموزش دیده، برای تغییر در مقادیر آن پیکسل‌ها استفاده می‌شود و برای استخراج واترمارک نیز پیکسل‌های حامل واترمارک و خروجی SVR با یکدیگر مقایسه می‌شوند. در تحقیقات محدودی نیز از SVR برای تعیین وفقی ضریب قوت واترمارک استفاده شده است. برای نمونه، در [۱۳،۱۴] یک الگوریتم واترمارکینگ وفقی بر اساس سیستم بینایی انسان مبتنی بر SVR ارائه گردیده که در آنها از SVR برای شبیه‌سازی سیستم بینایی انسان استفاده شده است. SVR با در نظر گرفتن ویژگی‌های بصری هر تصویر، ضریب قوت واترمارک را به صورت وفقی تعیین می‌کند.

این مقاله یک تکنیک واترمارکینگ جدید در حوزه DCT ارائه می‌دهد که در آن از SVM به علت توانایی بالای آن در مدل‌سازی سیستم بینایی انسان و قابلیت یادگیری، تعمیم و تقریب غیر خطی، برای تعیین وفقی ضریب قوت واترمارک استفاده می‌شود. بلوک‌های مختلف در تصویر بر اساس ویژگی‌های بافت و روشنایی توسط SVM به کلاس‌های مختلف طبقه‌بندی می‌شوند. سپس با ارائه تکنیکی جدید مبتنی بر الگوریتم ژنتیک ضریب قوت مناسبی برای هر کلاس تعیین می‌گردد. برای افزایش امنیت روش، مکان‌های جاسازی واترمارک، به شکل تصادفی

تصویر است و منظور از مقاومت، مقاوم بودن سیگنال واترمارک در برابر انواع تکنیک‌های پردازش تصویر و حملات عمدی و غیرعمدی است. این دو ویژگی در تضاد با یکدیگرند؛ یعنی همواره افزایش یکی باعث کاهش دیگری می‌گردد. مقاله‌های متعددی در جهت ایجاد توازن بین این دو ویژگی ارائه شده است. یکی از عوامل بسیار مؤثر در ایجاد توازن بین شفافیت و مقاومت، انتخاب وفقی و بهینه ضریب قوت واترمارک^۱ است. ضریب قوت واترمارک نمایانگر میزان تزریق واترمارک در تصویر میزبان است. افزایش این ضریب، باعث افزایش مقاومت و کاهش شفافیت می‌شود و برعکس. روش‌های واترمارکینگ وفقی مبتنی بر سیستم بینایی انسان^۲ (HVS) ضریب قوت واترمارک را به صورت وفقی متناسب با ویژگی‌های سیستم بینایی تعیین می‌کنند. یک تکنیک کلی در روش‌های واترمارکینگ وفقی مبتنی بر HVS این است که مکان‌های جاسازی واترمارک بر اساس ویژگی‌های سیستم بینایی طبقه‌بندی می‌شوند و سپس مطابق با طبقه‌بندی انجام شده ضریب قوت واترمارک مناسبی برای هر دسته تعیین می‌گردد [۱،۲]. در اکثر این روش‌ها طبقه‌بندی بلوک‌های تصویر با تعیین آستانه انجام می‌گیرد، اما از آنجا که سیستم بینایی انسان دارای ویژگی‌های پیچیده و غیر خطی است استفاده از آستانه‌گذاری برای طبقه‌بندی، مناسب نیست.

الگوریتم‌های هوشمند نظیر شبکه‌های عصبی، منطق فازی و الگوریتم ژنتیک نیز در سیستم‌های واترمارکینگ وفقی به طور گسترده استفاده شده‌اند. در [۳،۴] از شبکه عصبی برای مدل‌سازی سیستم بینایی انسان استفاده شده است که در آن‌ها شبکه عصبی با توجه به ویژگی‌های محلی تصویر نظیر آنروپی، روشنایی، فرکانس و حساسیت بافت، ضریب قوت واترمارک را به صورت وفقی تعیین می‌کند. در [۵] یک روش واترمارکینگ مبتنی بر الگوریتم ژنتیک ارائه شده است که در آن با استفاده از یک تابع برازندگی مناسب، الگوریتم ژنتیک مقادیر بهینه برای ضریب قوت واترمارک را معین می‌کند. در [۶،۷] نیز از الگوریتم ژنتیک برای بهینه کردن شفافیت و مقاومت واترمارکینگ در حوزه تبدیل کسینوسی گسسته^۳ (DCT) استفاده شده است. در [۸،۹] یک طرح واترمارکینگ در حوزه DCT بر اساس دسته‌بندی

ساده‌ترین حالت SVM را نشان می‌دهد که به آن SVM با حاشیه سخت^۹ گویند؛ جایی که داده‌های دو کلاس به صورت خطی قابل تفکیک هستند. H مرز تصمیمی است که داده‌های دو کلاس را از هم جدا می‌کند. H_1 و H_2 موازی با H در فاصله یکسانی از آن قرار دارند و از نزدیکترین نقاط به H می‌گذرند که به این نقاط، بردارهای پشتیبان^{۱۰} گویند. فاصله بین H_1 و H_2 نشان‌دهنده حاشیه^{۱۱} مرز تصمیم است و به طور کلی، هدف SVM یافتن مرز تصمیمی است که علاوه بر طبقه‌بندی داده‌های دو کلاس با حداقل خطا، بیش‌ترین حاشیه را نیز دارا باشد.

اگر $X_i, i = 1, \dots, m$ مجموعه داده‌های آموزشی باشند و داده‌ها در فضای n بعدی قرار داشته باشند ($X \in \mathbb{R}^n$) و $y_i \in \{-1, 1\}$ نمایانگر کلاس هر داده باشد، در صورتی که داده‌ها به صورت خطی قابل تفکیک باشند، می‌توان آنها را توسط یک فوق صفحه خطی از یکدیگر جدا نمود. معادله این فوق صفحه به صورت زیر بیان می‌شود:

$$H: W \cdot X + b = 0 \quad (1)$$

W بردار وزن است و در فضای n بعدی قرار دارد و b یک اسکالر است. $W \cdot X$ بیانگر ضرب داخلی دو بردار است. بردار W و اسکالر b موقعیت فوق صفحه را مشخص می‌کنند و داده‌ها به صورت زیر از یکدیگر مجزا می‌شوند.

$$\begin{cases} W \cdot X_i + b > 0 & \text{if } y_i = 1 \\ W \cdot X_i + b < 0 & \text{if } y_i = -1 \end{cases} \quad (2)$$

فاصله هر داده X_i تا فوق صفحه، توسط معادله زیر به دست می‌آید:


$$d(X_i) = \frac{y_i(W \cdot X_i + b)}{\|W\|} \quad (3)$$

انتخاب می‌شوند. نتایج نشان می‌دهند روش پیشنهادی شفافیت و مقاومت بالایی دارد.

در بخش دوم این مقاله، مرور جامعی بر SVM انجام می‌شود. در بخش سوم توضیح مختصری درباره ساختار الگوریتم ژنتیک داده می‌شود. در بخش چهارم الگوریتم جاسازی و استخراج واترمارک ارائه می‌گردد و سپس روشی برای تعیین ضریب قوت واترمارک توسط SVM و GA مطرح و در بخش آخر، نتایج حاصل از پیاده‌سازی ذکر می‌شود.

۲- ماشین بردار پشتیبان (SVM)

ماشین بردار پشتیبان (SVM) یک طبقه‌بندی کننده دودویی است که دو کلاس را با استفاده از یک مرز خطی از هم جدا می‌کند. نخستین بار SVM توسط وپنیک در اوایل دهه ۱۹۹۰ میلادی مطرح شد [۱۵]. SVM در بسیاری از مسائل مربوط به طبقه‌بندی داده‌ها و شناسایی الگو، همچون دسته‌بندی متون، تشخیص چهره در تصاویر، تشخیص ارقام دستنویس و بیوانفورماتیک کارکرد بسیار موفقی داشته است. از ویژگی‌های مهم SVM طبقه‌بندی داده‌ها بر اساس مینیمم‌سازی خطای ساختاری^{۱۲} یا همان خطای آزمایش است. اغلب طبقه‌بندی کننده‌های دیگر بر اساس مینیمم سازی خطای تجربی^{۱۳} یا همان خطای آموزش عمل می‌کنند. SVM در بخش آموزش به حل یک مسأله بهینه‌سازی محدب می‌پردازد و قادر به یافتن جواب مطلق مسأله است و بر خلاف روش‌هایی چون شبکه‌های عصبی، مشکل مینیمم‌های محلی را نخواهد داشت. شکل (۱-الف)



شکل (۱): ماشین بردار پشتیبان. (الف) SVM خطی با حاشیه سخت. (ب) SVM خطی با حاشیه نرم. (پ) SVM غیر خطی

خطا را نیز دارا باشد. نقاط خطا، داده‌هایی هستند که یا به اشتباه دسته‌بندی شده یا درون حاشیه مرز تصمیم قرار دارند. چنانچه فاصله این نقاط تا محل صحیح را به عنوان خطا (ε) در نظر بگیریم، می‌توان با حل مسأله بهینه‌سازی زیر مرز تصمیم بهینه را یافت:

$$\begin{cases} \text{minimize}_{W,b,\varepsilon} & \frac{1}{2}\|W\|^2 + C \sum_{i=1}^m \varepsilon_i \\ \text{subject to:} & \forall i \quad y_i(W \cdot X_i + b) \geq 1 - \varepsilon_i \\ & \varepsilon_i \geq 0 \end{cases} \quad (11)$$

پارامتر C بین ماکزیمم‌سازی حاشیه مرز تصمیم و مینیمم‌سازی خطای آموزش، توازن ایجاد می‌کند. برای داده‌هایی که درست طبقه‌بندی شده‌اند، صفر است. در اینجا نیز با تشکیل معادله لاگرانژ و دوگان آن، مسأله بهینه‌سازی فوق به رابطه (۷) تبدیل می‌شود؛ با این تفاوت که شرط $0 \leq \alpha_i \leq C$ برقرار است. پس از حل مسأله و یافتن ضرایب لاگرانژ مشاهده خواهد شد که این ضرایب برای نقاط بردار پشتیبان در محدوده $(0, C)$ و برای نقاط خطا برابر C و برای بقیه نقاط صفر است. بردار W و اسکالر b و طبقه‌بندی کننده نهایی از معادلات (۸) تا (۱۰) به دست می‌آیند.

علاوه بر طبقه‌بندی خطی، SVM برای مسائل طبقه‌بندی غیرخطی نیز به کار می‌رود. شکل (۱-پ) حالتی را نشان می‌دهد که داده‌های دو کلاس، توسط هیچ مرز خطی، قابل تفکیک نیستند. برای حل این مشکل، ابتدا داده‌ها از فضای ورودی \mathbb{R}^n ، با استفاده از یک تبدیل غیرخطی Φ ، به فضای ویژگی \mathbb{R}^d با ابعاد بالاتر منتقل می‌شوند.

$$\Phi: X \in \mathbb{R}^n \rightarrow \Phi(X) \in \mathbb{R}^d \quad d > n \quad (12)$$

در فضای جدید کلاس‌ها تداخل کمتری با یکدیگر دارند و می‌توان داده‌ها را به صورت خطی از یکدیگر جدا نمود. در نتیجه، عملیات غیرخطی در فضای ورودی به عملیات خطی در فضای ویژگی تبدیل خواهد شد. یافتن مرز تصمیم بهینه در فضای ویژگی مانند مباحث قبلی است و با قرار دادن $\Phi(X)$ به جای X در رابطه (۱۱) حاصل می‌شود.

در عمل چون ابعاد فضای ویژگی بسیار بزرگتر از ابعاد

یک فوق صفحه با حاشیه δ به صورت زیر تعریف می‌شود:

$$\forall i \quad d(X_i) \geq \delta \Rightarrow \forall i \quad \frac{y_i(W \cdot X_i + b)}{\|W\|} \geq \delta \quad (4)$$

$$\text{set } \delta = \frac{1}{\|W\|} \rightarrow \forall i \quad y_i(W \cdot X_i + b) \geq 1 \quad (5)$$

SVM مقادیر W و b را به گونه‌ای تعیین می‌کند که فوق صفحه مذکور عریض‌ترین حاشیه را در اطراف خود داشته باشد. به عبارت دیگر، مرز تصمیم بهینه را می‌توان با حل مسأله بهینه‌سازی زیر محاسبه نمود.

$$\begin{cases} \text{maximize}_{W,b} & \delta = \frac{1}{\|W\|} \equiv \text{minimize}_{W,b} \frac{1}{2}\|W\|^2 \\ \text{subject to:} & \forall i \quad y_i(W \cdot X_i + b) \geq 1 \end{cases} \quad (6)$$

این مسأله از طریق یافتن ضرایب لاگرانژ و تشکیل یک مسأله QP^{۱۱} محذب، قابل حل است. با تشکیل معادله لاگرانژ و دوگان مسأله، معادله زیر حاصل می‌شود:

$$\begin{cases} \max_{\alpha_i} L_D = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j y_i y_j (X_i \cdot X_j) \\ \text{subject to:} & \alpha_i \geq 0, \quad \sum_{i=1}^m \alpha_i y_i = 0 \end{cases} \quad (7)$$

α_i ها ضرایب لاگرانژ هستند. پس از حل مسأله بهینه‌سازی فوق، ضرایب لاگرانژ معین می‌گردند. این ضرایب برای نقاط بردار پشتیبان بزرگ‌تر از صفر و برای بقیه نقاط صفر هستند. با مشخص شدن ضرایب α_i بردار W معین می‌شود.

$$W = \sum_{i=1}^m \alpha_i y_i X_i \quad (8)$$

پس از یافتن W مقدار b با استفاده از رابطه زیر به ازای هر یک از بردارهای پشتیبان، محاسبه شده و b نهایی با میانگین‌گیری از b های محاسبه شده به دست می‌آید.

$$\forall (X_i, y_i) \in SV \rightarrow y_i(W \cdot X_i + b) = 1 \quad (9)$$

تابع طبقه‌بندی کننده نهایی از رابطه زیر به دست می‌آید:

$$F(X, W, b) = \text{sign}(W \cdot X + b) \quad (10)$$

شکل (۱-ب) یک مسأله طبقه‌بندی را نشان می‌دهد که داده‌ها توسط یک مرز تصمیم خطی همراه با مقداری خطا از یکدیگر متمایز شده‌اند. در این گونه مسائل که به آن SVM با حاشیه نرم^{۱۳} می‌گویند، هدف یافتن مرز تصمیمی است که علاوه بر داشتن بیشترین حاشیه، کمترین میزان

قرار داده، توسط هر طبقه‌بندی کننده، X به یک کلاس خاص تعلق می‌گیرد، در نهایت X متعلق به کلاسی خواهد بود که حداکثر آراء را بیاورد. در کاربردهای عملی، این روش کارایی بهتری نسبت به بقیه روش‌ها دارد [۱۷].

۳- الگوریتم ژنتیک (GA)

الگوریتم ژنتیک توسط پرفسور هلند طی دهه‌های ۱۹۶۰ و ۱۹۷۰ ارائه شد [۱۸]. از آن پس الگوریتم ژنتیک در کاربردهای مختلف زیادی آزمایش شد و در نهایت، توسط گلدبرگ به یکی از روش‌های بهینه‌سازی معروف تبدیل شد [۱۹]. الگوریتم ژنتیک روشی است برای بهینه‌سازی مسائل محدود و نامحدود و بر اساس فلسفه انتخاب اصلاح در طبیعت بنا شده است. الگوریتم ژنتیک به صورت تکراری، جمعیتی از راه حل‌ها را اصلاح می‌کند. در هر مرحله، الگوریتم ژنتیک تعدادی از افراد را از جمعیت کنونی انتخاب می‌کند تا والدینی برای فرزندان نسل بعد باشند. در نسل‌های متوالی، جمعیت به سوی راه حل بهینه پیش می‌رود. از الگوریتم ژنتیک برای حل بسیاری از مسائل بهینه‌سازی که با الگوریتم‌های استاندارد همخوانی ندارند، مانند توابع ناپیوسته، مشتق ناپذیر، تصادفی یا بسیار غیرخطی، می‌توان استفاده کرد.

ساختار کلی الگوریتم ژنتیک:

الگوریتم با تولید یک جمعیت اولیه تصادفی شروع می‌شود. در هر مرحله الگوریتم از افراد نسل کنونی استفاده کرده تا جمعیت جدیدی را بسازد. برای تولید جمعیت جدید، الگوریتم مراحل زیر را انجام می‌دهد:

۱. با محاسبه مقدار تابع برازندگی^{۱۷}، به هر عضو جمعیت کنونی ارزش می‌دهد. تابع برازندگی که در الگوریتم‌های بهینه‌سازی استاندارد همان تابع هدف مسئله است، میزان شایستگی هر عضو را ارزیابی می‌کند.
۲. ارزش‌های خام تابع را تغییر مقیاس می‌دهد تا در محدوده مناسبتری قرار بگیرند.

۳. الگوریتم ژنتیک والدین را بر اساس میزان شایستگی آن‌ها انتخاب می‌کند. روش‌های متداول برای انتخاب عبارتند از: روش چرخ رولت، انتخاب بولتزمن، انتخاب

فضای ورودی است، محاسبات در این فضا بسیار سنگین و پیچیده خواهد بود، به همین علت، معمولاً به جای استفاده از Φ ، از یک تابع هسته^{۱۴} استفاده می‌شود.

$$K(X_i, X_j) = \Phi(X_i) \cdot \Phi(X_j) \quad (13)$$

تابع هسته $K(X_i, X_j)$ در واقع یک تابع در فضای ورودی است که برابر با ضرب داخلی دو بردار در فضای ویژگی است. تابع $K(X_i, X_j)$ در صورتی می‌تواند یک تابع هسته باشد که در شرط مرسر^{۱۵} صدق کند و ماتریس حاصل از آن، متقارن، معین و مثبت باشد [۱۶].

برخی از مهمترین توابع هسته عبارتند از: تابع هسته چند جمله‌ای با درجه P ، تابع هسته گاوسی یا RBF و تابع هسته سیگموئید که به ترتیب در روابط زیر نشان داده شده است.

$$K(X_i, X_j) = (X_i \cdot X_j + 1)^P \quad (14)$$

$$K(X_i, X_j) = \exp(-\|X_i - X_j\|^2 / 2\sigma^2) \quad (15)$$

$$K(X_i, X_j) = \tanh(\gamma X_i \cdot X_j - \delta) \quad (16)$$

نتیجه اینکه، در یک طبقه‌بندی غیر خطی، ابتدا تابع هسته را مشخص نموده و سپس با حل مسأله بهینه‌سازی زیر، مرز تصمیم بهینه به دست می‌آید.

$$\begin{cases} \max_{\alpha_i} L_D = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j y_i y_j K(X_i, X_j) \\ \text{subject to: } 0 \leq \alpha_i \leq C, \quad \sum_{i=1}^m \alpha_i y_i = 0 \end{cases} \quad (17)$$

در پایان، پس از یافتن ضرایب لاگرانژ، تابع طبقه‌بندی کننده نهایی از رابطه زیر حاصل می‌شود:

$$F(X) = \text{sign} \left(\sum_{i=1}^m \alpha_i y_i K(X_i, X) + b \right) \quad (18)$$

SVM یک طبقه‌بندی کننده دودویی است. بنابراین، در حالتی که بیش از دو کلاس وجود داشته باشد، نمی‌توان مستقیماً از آن استفاده کرد. یکی از روش‌های موثر برای استفاده SVM در حالت چند کلاسه، روش یکی در مقابل یکی^{۱۶} است. در این روش‌ها هر بار دو تا از کلاس‌ها را در نظر گرفته، مرز تصمیم بین آن دو محاسبه می‌شود. پس برای k کلاس مختلف باید به تعداد $k(k-1)/2$ طبقه‌بندی کننده مجزا طراحی شود. برای طبقه‌بندی داده مجهول X ، آن را در همه طبقه‌بندی کننده‌های به دست آمده

ضریب قوت واترمارک را به صورت و فقی متناسب با ویژگی‌های بصری تصویر تعیین می‌کند.

در زیربخش اول و دوم الگوریتم جاسازی و استخراج واترمارک شرح داده می‌شود. در زیربخش سوم با استفاده از دو الگوریتم یادگیری ماشینی (ماشین بردار پشتیبانی و الگوریتم ژنتیک) و بهره‌گیری از ویژگی‌های سیستم بینایی انسان، روشی جدید برای تعیین و فقی ضریب قوت واترمارک ارائه می‌گردد.

۴-۱- الگوریتم جاسازی واترمارک

در این مقاله یک روش واترمارکینگ کور^{۲۰} در حوزه DCT معرفی شده است. بنابراین، در بخش استخراج واترمارک نیاز به دسترسی به تصویر اصلی نیست.

اگر تصویر میزبان، تصویر I با ابعاد $M \times N$ و تصویر واترمارک، یک تصویر باینری با ابعاد $M_w \times N_w$ باشد، برای جاسازی واترمارک در تصویر میزبان، ابتدا تصویر I به بلوک‌های 8×8 تقسیم و از هر یک تبدیل DCT گرفته می‌شود. سپس ضرایب DCT هر بلوک، به صورت زیگزاگی مرتب می‌گردند:

$$F_k = \text{DCT}(I_k) \quad 1 \leq k \leq k_t \quad (19)$$

$$F_k = \bigcup_{i=1}^{64} F_k(i) \quad 1 \leq k \leq k_t \quad (20)$$

F_k شامل ضرایب DCT بلوک k ام در تصویر میزبان I است که به صورت زیگزاگی مرتب شده‌اند و k_t تعداد کل بلوک‌های 8×8 در تصویر را نشان می‌دهد ($k_t = [M/8] \times [N/8]$). رابطه (۲۰) نشان می‌دهد هر بلوک DCT از اجتماع ۶۴ ضریب تشکیل شده است. شکل (۲) نحوه مرتب‌سازی ضرایب را نشان می‌دهد.

در مرحله بعد، جدول مرجع $R = \{R(i)\}$ ، $i \in [2, 64]$ ، مطابق با نسبت ضرایب AC به DC بلوک‌ها به صورت زیر محاسبه می‌شود:

$$R(i) = \frac{1}{k_t} \sum_{k=1}^{k_t} \frac{F_k(i)}{F_k(1)} \quad 2 \leq i \leq 64 \quad (21)$$

در این مقاله، برای افزایش امنیت واترمارکینگ، از دو

حالت پایدار، نخبه‌سالاری و انتخاب رقابتی [۲۰].

۴. الگوریتم ژنتیک از روی والدین، فرزندان را تولید می‌کند. به طور کلی، سه نوع فرزند در الگوریتم ایجاد می‌شود:

- فرزندان نخبه افرادی از جمعیت کنونی هستند که بهترین میزان برازندگی را دارند و مستقیماً به نسل بعد منتقل می‌شوند.

- فرزندان تقاطع^{۱۸} توسط ترکیب دو والد با یکدیگر ساخته می‌شوند. عمل تقاطع به الگوریتم این امکان را می‌دهد که بهترین ژن‌ها را از روی افراد مختلف انتخاب و با ترکیب آنها فرزندان برتر ایجاد کند. یک روش ساده برای تقاطع، انتخاب تصادفی یک نقطه برش و تولید فرزندی از ترکیب قسمتی از یک والد با قسمتی از یک والد دیگر است.

- فرزندان جهش^{۱۹} توسط ایجاد تغییرات تصادفی در یکی از افراد نسل کنونی ایجاد می‌شوند. معمولاً جهش روی فرزند حاصل از عمل تقاطع صورت می‌گیرد. عمل جهش، ژن‌هایی را که توسط فرایند انتخاب از جمعیت خارج می‌شوند، دوباره جایگزین می‌کند و در نتیجه آنها می‌توانند در حالت جدیدی بهبود یابند. در ضمن، ژن‌هایی را که در جمعیت اولیه حضور نداشته‌اند، به وجود می‌آورد.

۵. الگوریتم ژنتیک جمعیت کنونی را با فرزندان جایگزین می‌کند تا نسل بعد را تولید کند.

این الگوریتم آن قدر ادامه می‌یابد تا یکی از معیارهای توقف به وقوع بپیوندد. از شیوه‌های مختلفی می‌توان برای توقف الگوریتم استفاده کرد. برای نمونه، می‌توان همگرا شدن کل جمعیت و یا فاصله میزان برازندگی بهترین فرد جمعیت از متوسط میزان برازندگی‌ها را در نظر گرفت که در این حالت باید از حد مشخصی کوچکتر باشد یا می‌توان زمان معینی برای خاتمه الگوریتم یا تعداد نسل‌های مشخصی را به عنوان محک اختتام در نظر گرفت [۲۱، ۲۲].

۴- طرح واترمارکینگ پیشنهادی

در این بخش یک الگوریتم واترمارکینگ و فقی برای تصاویر دیجیتال در حوزه تبدیل DCT ارائه می‌گردد. روش پیشنهادی با بهره‌گیری از ویژگی‌های سیستم بینایی انسان،

مرجع در بخش جاسازی و استخراج واترمارک استفاده می‌شود. در نهایت، عمل جاسازی واترمارک، به ازای هر بیت به صورت زیر است:

$$B_K(c_K) = \begin{cases} \min(B_K(c_K), \bar{B}_K(c_K) - \alpha_K) & \text{if } w(K) = 0 \\ \max(B_K(c_K), \bar{B}_K(c_K) + \alpha_K) & \text{if } w(K) = 1 \end{cases} \quad (25)$$

α_K ضریب قوت واترمارک در بلوک B_K است. یکی از اهداف این مقاله، این است که این ضریب به صورت وقتی متناسب با شرایط بافت و روشنایی هر بلوک تعیین شود. در بخش ۳-۴ نحوه استفاده از ماشین بردار پشتیبان و الگوریتم ژنتیک برای تعیین وقتی ضریب قوت واترمارک بررسی می‌گردد.

پس از درج واترمارک، از بلوک‌های حاصل، عکس تبدیل DCT گرفته می‌شود تا تصویر I_w که تصویر حامل واترمارک است، به دست آید.

۴-۲- الگوریتم استخراج واترمارک

اگر تصویر I' با ابعاد $M' \times N'$ تصویر حامل واترمارک باشد، برای استخراج واترمارک ابتدا I' به بلوک‌های 8×8 تقسیم و از هر یک DCT گرفته می‌شود. سپس جدول مرجع R' برای آن طبق معادله (۲۱) محاسبه می‌گردد. در مرحله بعد، با استفاده از $key1$ ، بلوک‌های حامل واترمارک (B'_K) و با استفاده از $key2$ ، ضرابی که واترمارک در آنها جاسازی شده است (c'_K) مشخص می‌شوند: در نهایت، بیت‌های واترمارک w' از هر یک از بلوک‌های حامل واترمارک به صورت زیر استخراج می‌شوند.

$$w'(K) = \begin{cases} 1, & \text{if } B'_K(c'_K) \geq \bar{B}'_K(c'_K) \\ 0, & \text{else} \end{cases} \quad (26)$$

$\bar{B}'_K(c'_K)$ از رابطه زیر به دست می‌آید:

$$\bar{B}'_K(c'_K) = B'_K(1) \times R'(c'_K) \quad (27)$$

از آنجا که عمل جاسازی واترمارک در باند فرکانس میانی صورت می‌گیرد، در مقادیر DC بلوک‌ها تغییری داده نمی‌شود. از طرف دیگر، مقادیر جداول مرجع R و R' بسیار به هم نزدیک هستند، زیرا این جداول با میانگین‌گیری در تمامی بلوک‌ها به دست می‌آیند. بنابراین، می‌توان گفت مقادیر $\bar{B}_K(i)$ ، در بخش جاسازی و استخراج تقریباً ثابت

کلید $key1$ و $key2$ برای تعیین مکان‌های جاسازی واترمارک استفاده می‌شود. فرض می‌شود که تعداد بیت‌های واترمارک از تعداد بلوک‌های 8×8 در تصویر میزبان کمتر باشد ($M_w \times N_w \leq k_t$). بنابراین، در هر بلوک حداکثر یک بیت واترمارک جاسازی می‌شود. ابتدا توسط $key1$ ، به تعداد بیت‌های واترمارک، بلوک‌هایی از بین بلوک‌های DCT انتخاب می‌گردند که آنها را B_K می‌نامیم.

$$B_K \subseteq F_k \quad 1 \leq K \leq M_w \times N_w \quad 1 \leq k \leq k_t \quad (22)$$

$$B_K = \bigcup_{i=1}^{64} B_K(i) \quad 1 \leq K \leq M_w \times N_w \quad (23)$$

سپس توسط $key2$ ، در هر بلوک منتخب، یکی از ضرایب DCT در باند فرکانس میانی برای درج بیت واترمارک انتخاب می‌گردد. برای اینکه وابستگی ضرایب قوت واترمارک به مکان ضرایب DCT حداقل شود، تنها ضرایب ۱۱ تا ۱۵ بدین منظور استفاده می‌شود (شکل ۲).

$F_k(1)$	$F_k(2)$	$F_k(6)$	$F_k(7)$	$F_k(15)$	$F_k(16)$	$F_k(28)$	$F_k(29)$
$F_k(3)$	$F_k(5)$	$F_k(8)$	$F_k(14)$	$F_k(17)$	$F_k(27)$	$F_k(30)$	$F_k(43)$
$F_k(4)$	$F_k(9)$	$F_k(13)$	$F_k(18)$	$F_k(26)$	$F_k(31)$	$F_k(42)$	$F_k(44)$
$F_k(10)$	$F_k(12)$	$F_k(19)$	$F_k(25)$	$F_k(32)$	$F_k(41)$	$F_k(45)$	$F_k(54)$
$F_k(11)$	$F_k(20)$	$F_k(24)$	$F_k(33)$	$F_k(40)$	$F_k(46)$	$F_k(53)$	$F_k(55)$
$F_k(21)$	$F_k(23)$	$F_k(34)$	$F_k(39)$	$F_k(47)$	$F_k(52)$	$F_k(56)$	$F_k(61)$
$F_k(22)$	$F_k(35)$	$F_k(38)$	$F_k(48)$	$F_k(51)$	$F_k(57)$	$F_k(60)$	$F_k(62)$
$F_k(36)$	$F_k(37)$	$F_k(49)$	$F_k(50)$	$F_k(58)$	$F_k(59)$	$F_k(63)$	$F_k(64)$

شکل (۲): نحوه مرتب‌سازی ضرایب DCT

ضریب منتخب در بلوک B_K را c_K می‌نامیم. پس واترمارک را مشخص می‌کنند.

اکنون برای جاسازی واترمارک در تصویر میزبان، ابتدا

$\bar{B}_K(i)$ را به صورت زیر تعریف می‌کنیم:

$$\bar{B}_K(i) = B_K(1) \times R(i) \quad 1 \leq K \leq M_w \times N_w \quad (24)$$

$\bar{B}_K(i)$ تقریبی از $B_K(i)$ است و از آن به عنوان مقدار

بخش‌های مختلفی از تصویر با بافت و روشنایی متفاوت، حساسیت متفاوتی دارد. بر این اساس، می‌توان در سیستم‌های واترمارکینگ، برای نواحی مختلف تصویر، ضریب قوت واترمارک متفاوتی در نظر گرفت. برای مثال، در بافت‌های شلوغ، اطراف لبه‌ها و نواحی روشن یا تاریک می‌توان ضریب قوت واترمارک بزرگتری به کار برد.

در این مقاله، بلوک‌های مختلف تصویر بر اساس بافت و روشنایی، به کلاس‌های مختلف طبقه‌بندی می‌شوند و ضرایب قوت واترمارک متفاوتی برای هر کلاس تعیین می‌شود. با توجه به موارد فوق شش کلاس مختلف برای بلوک‌ها تعریف می‌شود.

- t_1 : بلوک‌های دارای بافت هموار با روشنایی زیاد؛
- t_2 : بلوک‌های دارای بافت هموار با روشنایی متوسط؛
- t_3 : بلوک‌های دارای بافت هموار با روشنایی کم؛
- t_4 : بلوک‌های دارای لبه؛
- t_5 : بلوک‌های دارای بافت نسبتاً شلوغ (بافت درشت)؛
- t_6 : بلوک‌های دارای بافت بسیار شلوغ (بافت ریز).

در این مقاله از چهار ویژگی برای طبقه‌بندی بلوک‌ها به کلاس‌های مذکور استفاده می‌شود: سطح روشنایی، آنتروپی، واریانس و کنتراست. به عبارت دیگر، از هر بلوک تصویر چهار ویژگی فوق استخراج شده، سپس بر اساس آن‌ها، کلاس متناظر با هر بلوک مشخص می‌گردد.

سطح روشنایی هر بلوک با میانگین‌گیری از مقادیر پیکسل‌های آن به دست می‌آید. هنگامی که روشنایی بلوک کم یا زیاد باشد، می‌توان ضریب قوت واترمارک بیشتری به کار برد. گشتاور دوم یا واریانس در توصیف بافت اهمیت ویژه‌ای دارد و معیاری از کنتراست شدت است که می‌توان از آن برای تعیین هموار بودن نسبی تصاویر استفاده کرد. آنتروپی معیاری است که نشان‌دهنده پراکندگی در شدت پیکسل‌هاست. در نتیجه، در تصاویر دارای بافت، مقادیر بزرگتری دارد. سطح روشنایی، واریانس و آنتروپی از روابط زیر به دست می‌آیند:

$$mean = \sum_{i=0}^{l-1} z_i P(z_i) \quad (28)$$

$$var = \sum_{i=0}^{l-1} (z_i - mean)^2 P(z_i) \quad (29)$$

بوده و به همین علت، از آن به عنوان مقدار مرجع استفاده می‌شود.

۴-۳- تعیین ضریب قوت واترمارک

در این بخش، تکنیک جدیدی برای تعیین فقی ضریب قوت واترمارک بر اساس ویژگی‌های محلی تصویر ارائه می‌گردد. تعیین فقی این ضریب شامل سه مرحله است:

۱. استخراج ویژگی‌های مناسب از بلوک‌های تصویر بر اساس خصوصیات سیستم بینایی انسان؛
۲. طبقه‌بندی بلوک‌ها به کلاس‌های مختلف بر اساس ویژگی‌های استخراج شده؛
۳. تعیین ضریب قوت واترمارک برای هر کلاس.

۴-۳-۱- استخراج ویژگی بر اساس HVS

جاسازی واترمارک در تصویر میزبان، در واقع اضافه نمودن یک نویز ضعیف به یک سیگنال قوی است و تا زمانی که قدرت نویز از آستانه JND ^{۲۱} کمتر باشد، چشم انسان قادر به تشخیص آن نخواهد بود. در سیستم دیداری انسان، عوامل مختلفی بر میزان حساسیت چشم نسبت به نویز تاثیر دارند که می‌توان به موارد زیر اشاره نمود:

- حساسیت به بافت: چشم انسان در بخش‌هایی از تصویر که بافت ناهموازی دارند، حساسیت کمتری نسبت به نویز دارد. به عبارت دیگر، اغتشاش در بخش‌هایی از تصویر که بافت شلوغی دارند، خیلی کمتر از نواحی با بافت هموار و یکنواخت، قابل رؤیت است.
 - پدیده پوشش^{۲۲}: به افزایش آستانه تحریک بصری یک سیگنال، بر اثر مجاورت با سیگنالی دیگر، پوشش گویند. یک عنصر تصویری می‌تواند قابلیت آشکارسازی عناصر تصویری مجاور آن را کاهش دهد. برای مثال، وجود لبه در ناحیه‌ای از تصویر، قابلیت رؤیت عناصر مجاور آن را کاهش می‌دهد.
 - حساسیت نسبت به میزان روشنایی: اعوجاج در بخش‌هایی از تصویر که سطح روشنایی خیلی بالا یا خیلی پایین دارند، کمتر از نواحی با روشنایی متوسط، قابل رویت است.
- این ویژگی‌ها نشان می‌دهند، چشم انسان در مقابل

استفاده می‌شود. هنگامی که آنتروپی و واریانس مقادیر کوچکی داشته باشند تصویر هموار است. اگر آنتروپی بزرگ باشد، در صورتی که واریانس مقدار بزرگی داشته باشد، لبه و در غیر این صورت بافت است. کنتراست نیز در تصاویر دارای بافت بسیار شلوغ (بافت ریز) مقادیر بزرگی دارد.

۴-۳-۲- طبقه‌بندی بلوک‌ها توسط SVM

برای تعیین ضرایب قوت واترمارک (α_K) در بلوک‌های جاسازی (B_K)، مطابق با آنچه در بخش قبل ذکر شد، ابتدا از تمام بلوک‌های B_K ، ویژگی سطح روشنایی، واریانس، آنتروپی و کنتراست استخراج می‌گردد و سپس بر اساس آن‌ها، بلوک‌ها به ۶ کلاس طبقه‌بندی می‌شوند.

در این مقاله، برای طبقه‌بندی بلوک‌ها از یک ماشین بردار پشتیبان آموزش دیده استفاده می‌گردد. در مقاله‌های پیش از این، که از طبقه‌بندی بلوک‌ها، برای وفقی نمودن واترمارکینگ استفاده شده است، عمدتاً روش‌های کلاسیک طبقه‌بندی مبتنی بر آستانه‌گذاری برای ویژگی‌های استخراجی، به کار رفته‌اند [۲۱]. استفاده از این طبقه‌بندی کننده‌ها دقت لازم را نخواهد داشت، زیرا سیستم بینایی انسان سیستمی کاملاً پیچیده و غیر خطی است. بنابراین در اینجا از SVM به علت توانایی بالای آن در شبیه‌سازی سیستم بینایی انسان و قابلیت یادگیری، تعمیم و تقریب غیرخطی، برای یافتن رابطه‌ای بین چهار ویژگی مذکور و کلاس‌های متناظر با آنها، استفاده می‌شود. برای به کارگیری SVM در طبقه‌بندی داده‌ها ابتدا باید آن را آموزش داد. به این منظور، در این مقاله از ۱۰۰۰ بلوک تصویری با بافت و روشنایی متفاوت به عنوان نمونه‌های آموزشی استفاده شده است [۲۴]. در نهایت، از SVM آموزش دیده برای تعیین کلاس بلوک‌های B_K استفاده می‌گردد.

$$\text{Class}(B_K) = \text{SVM}(\text{mean}_K, \text{var}_K, \text{ent}_K, \text{cont}_K) \quad (۳۳)$$

$$\text{Class}(B_K) \in \{t_1, t_2, t_3, t_4, t_5, t_6\} \quad (۳۴)$$

SVM، فرایند طبقه‌بندی داده‌ها از طریق ماشین بردار پشتیبان را نشان می‌دهد. از آنجا که تعداد کلاس‌ها بیش از دو تاست، از روش یکی در مقابل یکی برای طبقه‌بندی

$$\text{ent} = - \sum_{i=0}^{l-1} P(z_i) \log_2 P(z_i) \quad (۳۰)$$

در این روابط z_i نشان‌دهنده شدت روشنایی و l تعداد سطوح خاکستری است. $P(z_i)$ احتمال شدت روشنایی z_i در تصویر است و برابر نسبت تعداد پیکسل‌ها با روشنایی z_i به تعداد کل پیکسل‌های تصویر است.

معیارهای بافتی که فقط با استفاده از هیستوگرام محاسبه می‌شوند، مانند معیارهای فوق، هیچ اطلاعاتی درباره موقعیت نسبی پیکسل‌ها نسبت به یکدیگر حمل نمی‌کنند. این نکته در هنگام توصیف بافت مهم است و یک روش برای گنجانیدن این نوع اطلاعات در فرایند تحلیل بافت، در نظر گرفتن موقعیت نسبی پیکسل‌هاست. به این منظور، در این مقاله از معیار گشتاور تفاضلی عنصری^{۳۳} از مرتبه ۲ یا همان معیار کنتراست استفاده می‌گردد. برای این کار، ابتدا ماتریس هم‌رویدادی^{۳۴} برای بلوک تصویری مورد نظر تشکیل داده می‌شود. ماتریس هم‌رویدادی، ماتریسی است که عناصر آن تعداد دفعاتی را که جفت پیکسل‌های z_i و z_j در موقعیت خاصی نسبت به یکدیگر قرار می‌گیرند، نشان می‌دهند [۲۳]. در اینجا هر یک از عناصر این ماتریس (g_{ij}) نشان دهنده تعداد دفعاتی است که جفت پیکسل z_i و z_j در کنار هم، در همسایگی هشتگانه یکدیگر قرار می‌گیرند. معیار کنتراست برای هر بلوک تصویر به صورت زیر محاسبه می‌شود [۲۳]:

$$\text{cont} = \sum_{i=0}^{l-1} \sum_{j=0}^{l-1} (z_i - z_j)^2 P(z_i, z_j) \quad (۳۱)$$

z_i و z_j نمایانگر شدت روشنایی و $P(z_i, z_j)$ احتمال قرار گرفتن آنها در کنار یکدیگر است و به صورت زیر محاسبه می‌گردد:

$$P(z_i, z_j) = g_{ij}/n \quad (۳۲)$$

n تعداد کل جفت پیکسل‌هایی است که در کنار یکدیگر قرار گرفته‌اند و به عبارت دیگر، برابر مجموع عناصر ماتریس هم‌رویدادی است. همان‌طور که از رابطه (۳۱) مشاهده می‌شود، اگر تفاوت شدت روشنایی پیکسل‌های مجاور بیشتر باشد، کنتراست بیشتر خواهد بود. از واریانس، آنتروپی و کنتراست برای تعیین بافت بلوک

الگوریتم ژنتیک را نشان می‌دهد. الگوریتم ژنتیک با یک جمعیت اولیه از بردارهای S شروع به کار می‌کند. به ازای هر بردار S در جمعیت، تابع برازندگی محاسبه شده و سپس بر اساس مقادیر برازندگی حاصل تعدادی از آنها به عنوان والدین انتخاب می‌گردند. پس از انجام عملیات تقاطع و جهش بر روی والدین و ایجاد فرزندان، نسل بعدی شامل جمعیتی جدید از بردارهای S تشکیل می‌گردد. این روند ادامه می‌یابد تا جمعیت به یک بردار بهینه همگرا شود. در نهایت، برداری که بیشترین مقدار برازندگی را در نسل آخر دارد، جواب نهایی الگوریتم خواهد بود (S^*).

برای تعریف تابع برازندگی، میزان شفافیت واترمارکینگ از یک سو و میزان مقاومت واترمارک از سوی دیگر، برای هر یک از بردارهای S محاسبه می‌گردد. بنابراین، به ازای هر یک از بردارهای S عمل جاسازی واترمارک طبق آنچه در بخش ۴-۱ ذکر شد، انجام می‌شود. سپس برای ارزیابی شفافیت واترمارکینگ، میزان شباهت تصویر واترمارک شده با تصویر میزبان سنجیده می‌شود.

داده‌ها استفاده می‌شود ($mean_K, var_K, ent_K, cont_K$). بردار ویژگی استخراج شده از بلوک B_K است که شامل سطح روشنایی، آرنایس، آنتروپی و کنتراست است.

۳-۳-۴- تعیین ضرایب قوت واترمارک با GA

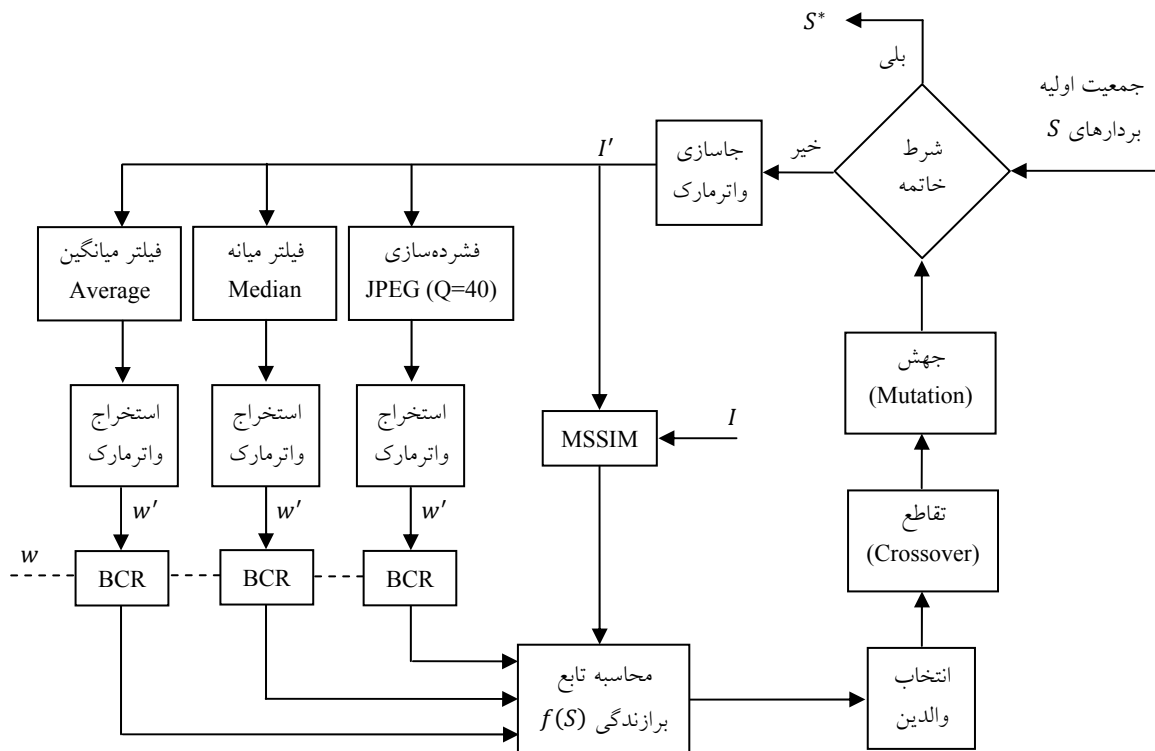
پس از طبقه‌بندی بلوک‌ها به شش کلاس مذکور، ضریب قوت واترمارک مناسب برای هر کلاس با استفاده از الگوریتم ژنتیک تعیین می‌شود. بردار S را به صورت زیر تعریف می‌کنیم که نمایانگر ضرایب قوت واترمارک در هر کلاس است.

$$S = [s_1, s_2, s_3, s_4, s_5, s_6] \quad (35)$$

s_i نشان دهنده ضریب قوت واترمارک در بلوک‌های کلاس t_i است ($s_i = S(t_i)$). هدف یافتن S بهینه توسط الگوریتم ژنتیک است. چنانچه S^* بردار بهینه حاصل از الگوریتم ژنتیک باشد، مقادیر α_K در بخش جاسازی واترمارک از رابطه زیر به دست می‌آید:

$$\alpha_K = S^*(Class(B_K)) \quad (36)$$

شکل (۳) بلوک دیاگرام نحوه یافتن S بهینه از طریق



شکل (۳): یافتن ضرایب قوت بهینه در هر کلاس توسط الگوریتم

شاخص شباهت ساختاری بین دو بلوک x و y از حاصل ضرب سه تابع مقایسه مذکور به دست می‌آید که با فرض $C_3 = C_2/2$ از رابطه زیر حاصل می‌شود:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (40)$$

در نهایت، شاخص شباهت ساختاری کل بین دو تصویر X و Y با میانگین‌گیری از مقادیر $SSIM$ به دست خواهد آمد.

$$MSSIM(X, Y) = \frac{1}{M} \sum_{i=1}^M SSIM(x_i, y_i) \quad (41)$$

M نشان‌دهنده تعداد بلوک‌های محلی در تصویر است که به صورت پیکسل به پیکسل بر روی تصویر جابه‌جا می‌گردند و x_i و y_i بلوک محلی i ام در دو تصویر X و Y را نشان می‌دهند. حداکثر مقدار شاخص شباهت ساختاری برابر یک است و تنها در صورتی محقق می‌شود که دو تصویر X و Y دقیقاً مشابه باشند.

پس از ارزیابی میزان شفافیت واترمارکینگ از طریق محاسبه شاخص شباهت ساختاری بین تصویر میزبان و تصویر واترمارک شده، برای ارزیابی میزان مقاومت واترمارک، تعدادی حمله و عملیات پردازش تصویری بر روی تصویر واترمارک شده انجام می‌پذیرد. سپس واترمارک از تصاویر مورد حمله طبق الگوریتم پیشنهادی در بخش ۴-۲ استخراج می‌گردد و شاخص BCR^{28} برای هر کدام، بین واترمارک اصلی و واترمارک استخراج شده محاسبه می‌شود.

$$BCR(w, w') = 1 - \frac{\sum_{i=1}^{M_w} \sum_{j=1}^{N_w} XOR(w(i, j), w'(i, j))}{M_w \times N_w} \quad (42)$$

حداکثر مقدار BCR یک است و تنها در صورتی که واترمارک اصلی و واترمارک استخراجی یکسان باشند، این مقدار حاصل می‌گردد.

تابع برازندگی برای هر یک از بردارهای S به صورت زیر تعریف می‌شود:

$$f(S) = MSSIM(I, I') + \frac{1}{p} \sum_{k=1}^p BCR_k(w, w') \quad (43)$$

I تصویر میزبان و I' تصویر واترمارک شده حاصل از جاسازی واترمارک در تصویر I با استفاده از بردار S است. p تعداد حملات اعمال شده بر روی تصویر I' را نشان

هم اکنون، ساده‌ترین و پرکاربردترین معیارهای سنجش شباهت MSE^{25} و $PSNR^{26}$ هستند و علت آن محاسبه ساده و در برداشتن یک معنای فیزیکی قابل فهم است، اما این معیارها با ویژگی‌های سیستم بینایی انسان تطابق خوبی ندارند. برای مثال، دو تصویر مخدوش با MSE یکسان می‌توانند دارای خطاهای متفاوتی باشند، به طوری که خطاهای یکی قابل مشاهده و دیگری غیرقابل مشاهده باشد. در سال‌های اخیر تلاش‌های زیادی در جهت ایجاد روش‌های ارزیابی کیفیت بر اساس سیستم بینایی انسان شده است و اکثر روش‌های پیشنهادی بر اساس اصلاح معیار MSE و با جریمه نمودن خطاها مطابق با میزان آشکاری آنها بنا نهاده شده است. این روش‌ها که معیارهای ارزیابی کیفیت مبتنی بر میزان حساسیت خطا نامیده می‌شوند نیز دارای اشکال‌ها و محدودیت‌هایی هستند. در [۲۵] محدودیت‌های این دسته از روش‌ها ذکر شده است و سپس شاخص جدیدی برای ارزیابی کیفیت تصویر مبتنی بر شباهت ساختاری بین دو تصویر معرفی گردیده است. این معیار که شاخص شباهت ساختاری 27 نامیده می‌شود، برای سنجش شباهت بین دو تصویر X و Y ، روشی، کنتراست و ساختار دو تصویر را مقایسه می‌کند. این مقایسه به صورت محلی در بلوک‌های متناظر در دو تصویر انجام می‌شود. اگر x و y بلوک‌های محلی متناظر در دو تصویر X و Y باشند، تابع مقایسه روشنایی $l(x, y)$ ، تابع مقایسه کنتراست $c(x, y)$ و تابع مقایسه ساختار $s(x, y)$ به صورت زیر تعریف می‌شوند [۲۵]:

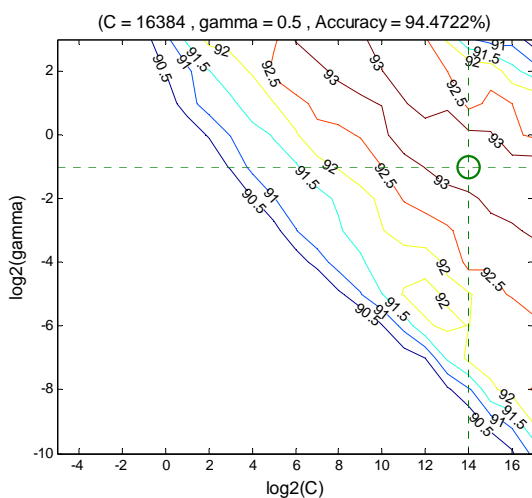
$$l(x, y) = \frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1} \quad (37)$$

$$c(x, y) = \frac{2\sigma_x\sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2} \quad (38)$$

$$s(x, y) = \frac{\sigma_{xy} + C_3}{\sigma_x\sigma_y + C_3} \quad (39)$$

C_1 ، C_2 و C_3 مقادیر ثابتی هستند که از ناپایداری معادله‌ها هنگامی که مخرج کسر مقدار کوچکی است، جلوگیری می‌کنند. μ_x و μ_y مقادیر متوسط در بلوک‌های x و y هستند و σ_x^2 و σ_y^2 نمایانگر مقادیر واریانس و σ_{xy} کوواریانس بین x و y را نشان می‌دهد.

بیشترین دقت را خواهد داشت که تقریباً برابر ۹۴٪ است. پس از تشکیل یک مدل SVM آموزش دیده و طبقه‌بندی بلوک‌ها توسط آن، ضرایب قوت واترمارک برای هر کلاس توسط الگوریتم ژنتیک تعیین می‌گردد. تعداد جمعیت اولیه را برابر ۶۰ قرار داده که در آزمایش‌های ابتدایی به صورت تصادفی تولید می‌شود. محدوده تغییرات هر یک از متغیرها در بازه [۱۰, ۱۰۰] در نظر گرفته می‌شود، چون به ازای ضرایب قوت کوچکتر از ۱۰ مقاومت اندکی در برابر حمله‌ها دارد و به ازای مقادیر بیشتر از ۱۰۰ شفافیت به طور قابل ملاحظه‌ای کاهش می‌یابد. معمولاً پس از طی حداکثر ۴۰ نسل جمعیت به یک مقدار بهینه همگرا می‌شود. شکل (۵) مقدار برازندگی بهترین کروموزوم و مقدار متوسط برازندگی کروموزوم‌ها، طی گذشت نسل‌های متوالی نشان می‌دهد که برای تصویر Lena به دست آمده است. در این نمودار محور افقی، نسل‌ها و محور عمودی، ارزش برازندگی را نشان می‌دهد. نقاط قرمز مقادیر برازندگی بهترین بردار S را در هر نسل نشان می‌دهد و نقاط آبی نشان‌دهنده متوسط مقادیر برازندگی تمام بردارها در هر نسل است. برای شبیه‌سازی، تابع برازندگی به صورت منفی تعریف شده است $(-f(S))$ و مسأله بهینه‌سازی با مینیم کردن آن حل می‌شود. به همین علت، مقادیر برازندگی در محور عمودی با علامت منفی مشخص شده‌اند.



شکل(۴): مقادیر بهینه C و γ حاصل از جستجوی شبکه‌ای

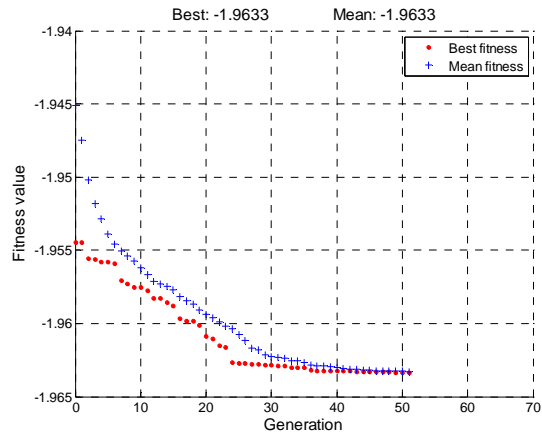
می‌دهد. w واترمارک اصلی و w' واترمارک استخراج شده از هر یک از تصاویر مورد حمله است. در این مقاله از سه حمله فیلتر میانگین، فیلتر میانه^{۲۹} و فشرده‌سازی JPEG با ضریب کیفیت ۴۰ برای ارزیابی میزان مقاومت واترمارک در تابع برازندگی استفاده می‌شود. از آنجا که شاخص BCR و SSIM محدوده تغییر مشابهی دارند، نیاز به وزن‌دهی در رابطه (۴۳) نیست، در حالی که اگر از شاخص PSNR استفاده شود، وجود یک پارامتر وزن ضروری است که تعیین بهینه آن مشکل است.

۴-۴- نتایج پیاده‌سازی

به منظور ارزیابی سیستم واترمارکینگ ارائه شده، روش پیشنهادی به طور گسترده بر روی تصاویر استاندارد تحت حمله‌های مختلف آزمایش گردید که در این بخش با توجه به محدودیت فضا به چند نمونه اشاره خواهیم کرد. تصاویر Lena, Baboon, Airplane, Cameraman, Peppers با ابعاد 512×512 به عنوان تصاویر میزبان و تصویر باینری Copyright با ابعاد 20×70 به عنوان واترمارک آزمایش می‌شوند.

در فرایند طبقه‌بندی بلوک‌ها، به یک مدل SVM آموزش دیده نیاز است. همان‌طور که پیش از این ذکر شد، از ۱۰۰۰ بلوک تصویری با بافت و روشنایی متفاوت به عنوان نمونه‌های آموزشی استفاده می‌گردد. پس از استخراج ویژگی‌ها از نمونه‌ها، داده‌های آموزشی حاصل به منظور کاهش حجم محاسبات به محدوده $[-1, 1]$ مقیاس می‌شوند. با آزمون توابع کرنل مختلف، در نهایت از کرنل RBF به علت کارایی بهتر و داشتن خطای آزمایش کمتر برای آموزش SVM استفاده می‌شود. سپس با جستجوی شبکه‌ای^{۳۰} بر روی مقادیر مختلف (C, σ) و تقریب خطای آزمایش به ازای هر یک از طریق Cross-validation مقادیر $C = 16384$ و $\sigma = 1$ برای آموزش SVM به کار می‌روند. C پارامتر ایجاد توازن بین حاشیه مرز تصمیم و خطای آموزش است و σ عرض کرنل RBF است. شکل (۴) مقادیر بهینه C و γ که از طریق جستجوی شبکه‌ای به دست آمده‌اند، نشان می‌دهد $(\gamma = 1/2\sigma^2)$. همان‌طور که مشاهده می‌شود، به ازای این مقادیر، طبقه‌بندی کننده حاصل

محسوسی بین تصاویر میزبان و تصاویر واترمارک شده قابل تشخیص نیست؛ از طرف دیگر، هنگامی که هیچ حمله‌ای بر روی تصاویر واترمارک شده اعمال نگردد واترمارک بدون هیچ خطایی استخراج می‌شود. معمولاً کیفیت یک سیستم واترمارکینگ با ارزیابی میزان شفافیت و مقاومت آن سنجیده می‌شود. در اینجا برای سنجش شفافیت روش، از شاخص SSIM بین تصاویر میزبان و تصاویر واترمارک شده استفاده می‌شود. جدول (۲) مقادیر SSIM را برای تصاویر مورد آزمایش نشان می‌دهد.



شکل (۵): نمودار تغییرات مقدار برازندگی بهترین کروموزوم و

متوسط مقادیر برازندگی طی نسل‌های متوالی

جدول (۱): بردارهای بهینه (S^*) حاصل از الگوریتم ژنتیک

	$S(t_1)$	$S(t_2)$	$S(t_3)$	$S(t_4)$	$S(t_5)$	$S(t_6)$
Lena	۲۳/۳۶	۱۸/۳۲	۲۶/۲۷	۳۸/۸۳	۳۶/۷۶	۶۰/۴۳
Baboon	۲۲/۹۱	۱۸/۳۲	۲۶/۳۸	۶۱/۷۶	۴۸/۶۶	۸۵/۹۶
Peppers	۲۳/۵۶	۲۰/۸۷	۲۴/۶۵	۳۸/۵۷	۳۲/۹۶	۶۱/۴۶
Airplane	۲۱/۳۵	۱۸/۲۶	۲۳/۷۱	۳۹/۱۱	۳۷/۸۶	۷۹/۱۲
Cameraman	۲۱/۷۳	۱۹/۵۹	۲۱/۲۵	۳۱/۲۶	۴۲/۴۱	۵۴/۴۱

با انجام این آزمایش‌ها بر روی تصاویر مختلف که دارای بافت و روشنایی متفاوت هستند، مجموعه‌ای از بردارهای بهینه حاصل می‌گردد که می‌توان از آنها در جمعیت اولیه برای تصاویر بعدی استفاده نمود.

جدول (۱) حاوی بردارهای بهینه حاصل از الگوریتم ژنتیک برای هر یک از تصاویر مورد آزمایش است. همان‌طور که مشاهده می‌شود، ضریب قوت واترمارک در بافت‌های بسیار شلوغ ($S(t_6)$) بیشترین مقدار و در بافت‌های هموار با روشنایی متوسط ($S(t_2)$)، کمترین مقدار را دارد.

پس از تعیین بردار S بهینه توسط الگوریتم ژنتیک برای هر یک از تصاویر میزبان، عمل جاسازی واترمارک طبق الگوریتم ارائه شده در این مقاله، انجام می‌گیرد. شکل (۶) تصاویر واترمارک شده به همراه واترمارک استخراج شده از آنها را نشان می‌دهد. از راست به چپ، به ترتیب تصاویر اصلی، تصاویر واترمارک شده و واترمارک استخراجی مشخص شده‌اند. همان‌طور که مشاهده می‌شود، تفاوت


جدول (۲): نتایج جاسازی واترمارک در تصاویر میزبان

تصاویر میزبان	SSIM	
	روش پیشنهادی	روش [۲۴]
Lena	۰/۹۸۹۸	۰/۹۹۰۸
Baboon	۰/۹۸۶۲	۰/۹۸۹۱
Peppers	۰/۹۸۹۴	۰/۹۹۰۶
Airplane	۰/۹۹۰۵	۰/۹۹۰۷
Cameraman	۰/۹۸۸۶	۰/۹۸۹۲

Copyright



Copyright



Copyright



Copyright



Copyright



(پ)

(ب)

(الف)

شکل (۶): (الف): تصاویر میزبان؛ (ب): تصاویر حامل واترمارک؛ (پ): واترمارک‌های استخراج شده



شکل (۷): نتایج آشکارسازی واترمارک تحت حملات مختلف:

(الف): فشرده‌سازی JPEG با ضریب کیفیت ۴۰ (BCR=۱)؛ (ب): JPEG با ضریب کیفیت ۳۰ (BCR=۰/۹۶۴۲)؛ (پ): فیلتر تیزکننده (BCR=۱)؛
 (ت): تعدیل هیستوگرام (BCR=۰/۹۹۵۷)؛ (ث): افزودن نویز گاوسی جمع شونده (BCR=۰/۹۶۲۸)؛ (ج): نویز ضرب شونده speckle (BCR=۰/۹۵۲۴)؛
 (چ): نویز نمک و فلفل (BCR=۰/۹۵۱۴)؛ (ح): فیلتر میانه (BCR=۰/۹۸۵۷)؛ (خ): فیلتر میانگین (BCR=۰/۹۸۷۸)؛ (د): فیلتر پایین گذر گاوسی (BCR=۱)؛
 (ذ): فیلتر وینر (BCR=۰/۹۹۸۵)؛ (ر): فیلتر a -trimmed (BCR=۰/۹۸۷۱)؛ (ز): فیلتر نقطه میانی (BCR=۰/۹۰۷۹)؛
 (ز): تغییر ابعاد تصویر با ضریب ۰/۷۵ (BCR=۱)؛ (س): تغییر ابعاد تصویر با ضریب ۱/۳ (BCR=۱)

مقاومت روش، از شاخص BCR بین واترمارک اصلی و واترمارک استخراج شده، استفاده می‌شود.

جدول (۳) مقادیر BCR را به ازای حمله‌های مختلف برای واترمارک استخراج شده از تصاویر مورد آزمایش نشان می‌دهد. همان‌طور که مشاهده می‌شود، روش واترمارکینگ پیشنهادی توازن خوبی بین شفافیت و مقاومت ایجاد کرده است. واترمارک در برابر اکثر حمله‌ها مقاوم است و در حمله‌هایی مانند تغییر ابعاد، فشرده‌سازی JPEG با ضریب کیفیت ۴۰، فیلتر پایین‌گذر گاوسی و فیلتر تیزکننده بدون خطا قابل استخراج است. در حمله تغییر ابعاد، ابتدا تصویر واترمارک شده با ضریب مورد نظر کوچک یا بزرگ می‌شود

برای محاسبه شاخص SSIM، مقادیر C_1 و C_2 به صورت زیر به دست می‌آیند:

$$C_1 = (k_1 L)^2, \quad k_1 = 0.01 \quad (44)$$

$$C_2 = (k_2 L)^2, \quad k_2 = 0.03$$

L محدوده پویای مقادیر پیکسل‌هاست که در اینجا

برابر ۲۵۵ است. در ضمن، مقادیر $\mu_x, \mu_y, \sigma_x^2, \sigma_y^2$ در بلوک‌های 11×11 و به صورت وزن‌دار توسط یک پنجره گاوسی متقارن نرمالیزه شده محاسبه می‌شوند [۲۵].

برای ارزیابی میزان مقاومت روش، چندین حمله بر روی تصاویر واترمارک شده اعمال می‌گردد. شکل (۷) تعدادی از این حمله‌ها را به همراه واترمارک استخراجی از آنها برای تصویر Lena نشان می‌دهد. برای سنجش میزان

ضرایب قوت واترمارک استفاده شده است. در مقاله مذکور ضرایب قوت واترمارک به صورت تجربی و روش سعی و خطا به دست آمده‌اند و برای هر یک از کلاس‌ها در هر تصویر مقدار ثابتی دارند. در جداول (۲) و (۳) نتایج این روش را می‌توان با الگوریتم پیشنهادی مقایسه نمود. نتایج نشان می‌دهد با وجود شفافیت بالای هر دو روش، الگوریتم پیشنهادی دارای مقاومت بسیار بالاتری است. این موضوع در تصاویر دارای بافت مثل تصویر Baboon کاملاً مشهود است.

سپس برای استخراج واترمارک، تصویر مورد حمله دوباره به اندازه ابعاد اصلی بازسازی می‌شود. تمام فیلترها توسط پنجره‌های 3×3 بر روی تصویر واترمارک شده اعمال می‌شوند. عرض فیلتر پایین‌گذر گاوسی $\sigma = 0.5$ است. فیلتر نقطه میانی^{۳۱}، میانگین مقادیر ماکزیمم و مینیمم پنجره را جایگزین پیکسل مرکزی می‌کند. فیلتر α -trimmed مقادیر پنجره را به صورت یک دنباله مرتب می‌کند، سپس از ابتدا و انتهای آن با اندازه α برش می‌دهد و میانگین اعداد باقیمانده را جایگزین پیکسل مرکزی می‌کند. در [۲۴] نیز از طبقه‌بندی بلوک‌ها برای وفقی نمودن

جدول (۳): نتایج آشکارسازی واترمارک تحت حملات مختلف

	Lena		Baboon		Peppers	Airplane	Cameraman
	روش پیشنهادی	روش [۲۴]	روش پیشنهادی	روش [۲۴]			
histogram equalization	۰/۹۹۵۷	۰/۹۹۴۲	۰/۹۹۸۵	۰/۹۸۷۸	۰/۹۹۴۲	۰/۹۹۷۱	۰/۹۹۵
Scaling 1.3	۱	۰/۹۸۸۵	۱	۰/۹۷۲۱	۱	۱	۱
Scaling 0.75	۱	۰/۹۶۰۷	۱	۰/۹۵۲۱	۱	۱	۱
Salt & pepper noise	۰/۹۵۱۴	۰/۹۰۳۵	۰/۹۹۴۲	۰/۹۲۰۷	۰/۹۴۸۵	۰/۹۴۵	۰/۹۳۵
multiplicative Speckle noise	۰/۹۵۲۴	۰/۹۱۱۴	۰/۹۹۵	۰/۹۱۷۱	۰/۹۶۵۷	۰/۸۹۷۱	۰/۹۲۲۸
additive Gaussian white noise	۰/۹۶۲۸	۰/۹۲۵	۰/۹۹۵۷	۰/۹۳۳۵	۰/۹۷۱۴	۰/۹۶۲۱	۰/۹۵۳۵
JPEG 30	۰/۹۶۴۲	۰/۷۳۲۱	۰/۹۹۸۵	۰/۷۶	۰/۹۹۷۸	۰/۹۵۵	۰/۹۹۵
JPEG 40	۱	۰/۸۹۱۴	۱	۰/۸۹۰۷	۱	۱	۱
Sharpening	۱	۰/۹۸۵	۱	۰/۹۷۲۱	۱	۱	۱
α -trimmed filter ($\alpha=2$)	۰/۹۸۷۱	۰/۸۶۳۵	۰/۹۸۵	۰/۷۴۳۵	۰/۹۸۵۷	۰/۹۸۵۷	۰/۹۷۵
Midpoint filter	۰/۹۰۷۹	۰/۷۵۳۵	۰/۹۱۷۹	۰/۶۷۰۷	۰/۹۲۲۸	۰/۸۹۷۸	۰/۸۶
Wiener filter	۰/۹۹۸۵	۰/۸۹۴۲	۰/۹۹۸۵	۰/۸۳۷۸	۰/۹۹۴۲	۰/۹۹۵	۰/۹۷۰۷
Averaging filter	۰/۹۸۷۸	۰/۸۳۹۲	۰/۹۸۰۷	۰/۷۴۵۷	۰/۹۸۶۴	۰/۹۸۱۴	۰/۹۶۴۲
Gaussian low pass filter	۱	۰/۹۸۷۱	۱	۰/۹۸۵۷	۱	۱	۱
Median filter	۰/۹۸۵۷	۰/۸۸۴۲	۰/۹۷۷۸	۰/۷۴۱۴	۰/۹۹۰۷	۰/۹۹۰۷	۰/۹۸۴۲

انسان به کار گرفته شدند. برای تعیین خصوصیات بصری بخش‌های مختلف تصویر، چهار ویژگی متفاوت از بلوک‌های تصویر استخراج گردید. روشنایی، آنتروپی و واریانس ویژگی‌های متداولی هستند که در اکثر مقاله‌ها از آنها برای تعیین نوع بافت و میزان روشنایی استفاده می‌شود. در این مقاله از ویژگی دیگری نیز برای تعیین بافت استفاده

۵- نتیجه‌گیری

در این مقاله یک روش واترمارکینگ و فقی مبتنی بر سیستم بینایی انسان در حوزه DCT ارائه گردید که در آن برای تعیین وفقی ضرایب قوت واترمارک در مکان‌های جاسازی، برخی از ویژگی‌ها و محدودیت‌های سیستم بینایی

- Neural Network to Estimate Watermark Embedding Strength", Eighth International Workshop on, Image Analysis for Multimedia Interactive Services, pp. 68-68, 2007.
- [5] N. Zhong, J.-M. Kuang and Z.-W. He, "A GA-based Optimal Image Watermarking Technique", Third International Conference on, Intelligent Information Hiding and Multimedia Signal Processing, vol. 1, pp. 291-294, 2007.
- [6] P. Kumsawat, K. Attakitmongkol and A. Srikaew, "A new approach for optimization in image watermarking by using genetic algorithms", IEEE Transactions on, Signal Processing, vol. 53, pp. 4707-4719, 2005.
- [7] C.-S. Shieh, H.-C. Huang, F.-H. Wang and J.-S. Pan, "Genetic watermarking based on transform-domain techniques", Pattern Recognition, vol. 37, pp. 555-565, 2004.
- [8] W. Jianzhen and X. Jianying, "Adaptive image watermarking scheme based on HVS and fuzzy clustering theory", Proceedings of the 2003 International Conference on, Neural Networks and Signal Processing, vol. 2, pp. 1493-1496, 2003.
- [9] S. E. El-Khany and N. A. El-Yamany, "A new perceptual image watermarking technique based on adaptive fuzzy clustering", presented at Radio Science Conference, Proceedings of the Twenty-First National, 2004.
- [10] A. M. Latif, V. Derhami and A. R. Naqsh-Nilchi, "Determine the watermark strength in digital image watermarking based on reinforcement learning", 6th International Conference on Information Security and Cryptology, 2009. (in Persian)
- [11] X.-Y. Wang and C.-Y. Cui, "A novel image watermarking scheme against desynchronization attacks by SVR revision," Journal of Visual Communication and Image Representation, vol. 19, pp. 334-342, 2008.
- [12] L. Chun-hua, L. Zheng-ding and Z. Ke, "An image watermarking technique based on support vector regression", IEEE International Symposium on, Communications and Information Technology, vol. 1, pp. 183-186, 2005.
- [13] L. Jun, P. Hong and P. Zheng, "Adaptive Watermarking Algorithm Using SVR in Wavelet Domain", 6th IEEE/ACIS International Conference on, Computer and Information Science, pp. 207-211, 2007.
- [14] S. Yuanhai, L. Chan and C. Wei, "Based on SVR Adaptive Watermarking Technique in DCT Domain", International Conference on, Neural Network to Estimate Watermark Embedding Strength", Eighth International Workshop on, Image Analysis for Multimedia Interactive Services, pp. 68-68, 2007.
- گرديد که کنتراست نام دارد. با استفاده از این ویژگی می‌توان بخش‌هایی از تصویر را که دارای بافت بسیار شلوغ هستند شناسایی نمود و ضریب قوت واترمارک بزرگی را در این بخش‌ها به کار برد. بنابراین، نتیجه گرفته می‌شود اضافه نمودن این ویژگی تاثیر بسزایی در کارایی روش واترمارکینگ پیشنهادی، مخصوصاً در افزایش مقاومت آن داشته است.
- سپس از ماشین بردار پشتیبان برای طبقه‌بندی بلوک‌های تصویر به شش کلاس مختلف بر اساس ویژگی‌های استخراج شده، استفاده گردید. در نهایت، با ارائه روشی مبتنی بر الگوریتم ژنتیک، ضرایب قوت بهینه برای هر کلاس تعیین شد. تابع برازندگی به صورت تابعی از شفافیت و مقاومت واترمارکینگ تعریف شد که در آن از شاخص شباهت ساختاری (SSIM) به منظور ارزیابی شفافیت و از شاخص نرخ صحت بیت (BCR) برای ارزیابی مقاومت استفاده شد. نتایج نشان دادند، تابع برازندگی تعریف شده، عملکرد مناسبی در تعیین مقادیر بهینه برای ضرایب قوت واترمارک در کلاس‌های مختلف داشته است.
- نتایج پیاده‌سازی نشان دادند استفاده از ماشین بردار پشتیبان و الگوریتم ژنتیک در تعیین ضرایب قوت واترمارک در بخش‌های مختلف تصویر مفید بوده است. روش پیشنهادی به طور گسترده تحت حمله‌های مختلف آزمایش شد و با توجه به نتایج پیاده‌سازی، الگوریتم ارائه شده توازن خوبی بین شفافیت و مقاومت ایجاد نموده است و در برابر حمله‌ها و پس پردازش‌ها مقاومت خوبی دارد.

مراجع

- [1] J. Huang, Y. Q. Shi and R. Yao, "Adaptive image watermarking based on block classification", Journal of image and graphics, vol. 4, no. 8, pp. 640-643, 1999.
- [2] Z. Lu, S. Jiang and H. Dong, "Adaptive watermarking algorithm based on human visual system", Journal of harbin institute of technology, vol. 35, no. 2, pp. 138-141, 2003.
- [3] L. Der-Chyuan, L. Jiang-Lung and H. Ming-Chiang, "Adaptive digital watermarking using neural network technique", IEEE International Carnahan Conference on, Security Technology, pp. 325-332, 2003.
- [4] J. Cong and W. Shihui, "Applications of a

- 6- Support Vector Regression
 7- Structural risk minimization
 8- Empirical risk minimization
 9- Hard-margin SVM
 10- Support vectors
 11- Margin
 12- Quadratic Programming
 13- Soft-margin SVM
 14- kernel
 15- Mercer
 16- one-against-one
 17- Fitness function
 18- Crossover
 19- Mutation
 20- Blind
 21- Just Noticeable Difference
 22- Masking
 23- Element difference moment
 24- Co-occurrence matrix
 25- Mean square error
 26- Peak signal to noise ratio
 27- Structural Similarity Index
 28- Bit Correct Rate
 29- Median filter
 30- Grid search
 31- Midpoint
- Management and Service Science, pp. 1-4, 2009.
- [15] V. Vapnik, "The Nature of Statistical Learning Theory", Springer Verlag, 2000.
- [16] V. Vapnik and A. Chervonenkis, "The necessary and sufficient conditions for consistency in the empirical risk minimization method", Pattern Recognition and Image Analysis, vol. 1, no. 3, pp. 283-305, 1991.
- [17] C.-W. Hsu and C.-J. Lin. "A comparison on methods for multi-class support vector machines", IEEE Transactions on Neural Networks, vol. 13, no. 2, pp. 415-425, 2002.
- [18] J.H. Holland, "Adaptation in Natural and Artificial Systems", The University of Michigan Press, Ann Arbor, MI, 1975.
- [19] D.E. Goldberg, "Genetic Algorithms in Search, Optimization and Machine Learning", Addison-Wesley, 1989.
- [20] M. Mitchell, "An introduction to genetic algorithms", A Bradford Book The MIT Press, Fifth printing, 1999.
- [21] A. L. C. Bazzan, S. Labidi, M. Safe, J. Carballido, I. Ponzoni and N. Brignole, "On Stopping Criteria for Genetic Algorithms", in Advances in Artificial Intelligence, vol. 3171, Lecture Notes in Computer Science: Springer Berlin / Heidelberg, pp. 405-413, 2004.
- [22] H. Aytug and G. J. Koehler, "Stopping criteria for finite length genetic algorithms", INFORMS Journal on Computing, vol. 8, pp. 183, 1996.
- [23] R. C. Gonzalez and R. E. Woods, "Digital image processing, 3rd Ed", Prentice Hall, 2008.
- [24] F. Meng, H. Peng, Z. Pei, and J. Wang, "A Novel Blind Image Watermarking Scheme Based on Support Vector Machine in DCT Domain", IEEE International Conference on, Computational Intelligence and Security, 2008.
- [25] Z. Wang, A. C. Bovik, H. R. Sheikh and E. P. Simoncelli, "Image quality assessment: From error visibility to structural similarity", IEEE Transactions on Image Processing, vol. 13, pp. 600-612, 2004.

زیر نویس ها:

- 1- Watermarking strength
- 2- Human visual system
- 3- Discrete cosine transform
- 4- Reinforcement learning
- 5- Support Vector Machine