

طراحی روشی کارآمد در فشرده سازی چند مرحله‌ای تصاویر ماموگرافی جهت ذخیره سازی و انتقال بهینه بر مبنای شبکه‌های عصبی مصنوعی و الگوریتم L-M

بهاره نصرتی نیا^۱، جواد حدادنیا^{۲*}

تاریخ دریافت: ۹۳/۸/۱۳

تاریخ پذیرش: ۹۴/۳/۲۷

چکیده:

زمینه و هدف: در فرایند پزشکی از راه دور (Telemedicine)، استفاده از تکنیک‌های دیجیتالی در تشخیص بیماری‌ها سبب شده تا پزشکان جهت آرشیو و نگهداری اطلاعات بیماران به منابع ذخیره‌سازی و نیز پهنای باند بالا در انتقال داده‌ها نیاز پیدا کنند.

مواد و روشها: هدف از ارائه این مقاله، معرفی یک شیوه کارآمد در فشرده‌سازی چند مرحله‌ای اطلاعات مربوط به تصاویر ماموگرافی بر اساس شبکه‌های عصبی مصنوعی و الگوریتم L-M بود. در ابتدا تصویر ماموگرافی با ورود به شبکه عصبی، این امکان را خواهد داشت که با کمترین میزان تخریب و درجه فشردگی بالا در لایه نخست فشرده شود.

نتایج: پیاده سازی مراحل فشرده‌سازی تصاویر ماموگرافی با استفاده از تصاویر ۱۲۸ زن با سنین ۴۶/۴۱±۶/۵۵ سال و شاخص توده بدنی ۳۶/۷۸±۵/۵ از سطح ۳ کلینیک تخصصی از شهر سبزوار صورت گرفت. مشاهده شد که به ترتیب متوسط مجذورات خطا برابر (MSE) ۴/۲۴، بیشترین نسبت تفاوت برابر ۳۳/۴۶ و نسبت فشرده سازی ۸:۱ در خروجی الگوریتم حاصل آمدند؛ عملکرد قابل قبول سیستم بر اساس طراحی دقیق نرم افزاری بوده و به همین دلیل کارایی مناسبی را در عمل به همراه داشت.

نتیجه گیری: بر مبنای قابلیت اطمینان به خروجی نرم افزار در فشرده‌سازی و انتشار و به دلیل عدم تخریب اطلاعات اساسی تصاویر ماموگرافی در زمان فشرده شدن، تشخیص در مرحله اکتشاف با تشخیص در واقعیت مطابقت بالایی دارد و از این رو سیستم امکان پیاده‌سازی را در مراکز بیمارستانی در آرشیو تصاویر ماموگرافی داراست و کاربرد آن را توجیه می‌کند.

کلمات کلیدی: سرطان، پستان نگاری، پردازش تصویر، فشرده سازی تصویر و شبکه های عصبی

^۱ دانشجوی کارشناسی ارشد مهندسی الکترونیک، گروه مهندسی پزشکی، دانشکده مهندسی برق و کامپیوتر، دانشگاه حکیم سبزواری، سبزوار، ایران.

^۲ دانشیار، گروه مهندسی پزشکی، دانشگاه حکیم سبزواری، سبزوار، ایران. (*نویسنده مسوول) آدرس: استان خراسان رضوی، سبزوار، بالاتر از توحید شهر، دانشگاه حکیم سبزواری، دانشکده برق و کامپیوتر، تلفن: ۰۵۱-۴۴۰۱۲۶۰۱، آدرس الکترونیکی: Haddadnia@hsu.ac.ir

مقدمه

پیشرفت‌های فنی حوزه مهندسی باعث تسهیل در توسعه زمینه‌های مختلف پزشکی شده و از آن قبیل می‌توان به تشخیص بیماری‌های مختلف از طریق تصویربرداری اشاره نمود که سبب می‌شود تا مطالعه بر روی بیماران به شیوه‌ای کاملاً غیر تهاجمی محقق گردد. این روش‌ها از رادیوگرافی توسط اشعه X آغاز می‌شوند و به تکنیک‌های پیچیده‌ای چون اکوگرافی، CAT، MRI و ... ختم می‌شوند و همه آنها به نحوی با مفهوم کنتراست تصویر در ارتباط هستند. یکی از این شیوه‌ها، روش تصویر برداری ماموگرافی (Mammography) است که در مشاهده تشخیص سرطان سینه به رادیولوژیست‌ها و پزشکان کمک می‌کند تا بتوانند وجود تومورهای احتمالی را آشکار کنند [۲۰]. پیشرفت‌های کنونی در ماموگرافی به طور مستقیم موثر از نتایج بدست آمده از تکنولوژی‌های آشکار سازی و الگوریتم‌های مرتبط با محاسبات نرم است [۲]. رشد تجهیزات پرتونگاری مقطعی (Tomography) از بافت [۴ و ۳] در ماموگرافی دیجیتالی [۵ و ۶] سبب شده تا ذخیره این تصاویر به فضای بسیار زیادی نیاز داشته و همچنین در زمان انتقال آن پهنای باند گسترده‌ای در دسترس باشد. از این رو در بسیاری از روش‌های بالینی نیاز به تکنولوژی‌های جدید ضروری به نظر می‌آید و در مقوله فشرده‌سازی داده‌های تصویری، جای تکنیکی کارآمد حس می‌شود.

پردازش دیجیتالی تصاویر این امکان را فراهم آورده تا بازیابی مطمئن، ذخیره‌سازی کارآمد و انتقال اطلاعات تصویری در شناسایی بیماری ایجاد گردد و از طرفی حفظ و نگهداری حجم گسترده‌ای از داده‌های مربوط به بیماران آسانتر شود [۷]. مزایای عمده این حوزه زمانی خود را نشان خواهد داد که بتوان اطلاعات تصویری را به فرمت دیجیتالی تبدیل نمود؛ بطور مثال اطلاعات مربوط به تصاویر رادیوگرافی یا MRI با تبدیل به فرمت دیجیتالی در بردارنده اطلاعات قابل تحلیل و مناسبی خواهند بود. در مجموع در تصاویر پزشکی مانند یک تصویر ماموگرافی با حجم بالایی از اطلاعات مواجه هستیم و اغلب این اطلاعات در سیستم‌های کامپیوتری موجود در سطح بیمارستان‌ها یا مطب‌ها ذخیره می‌شوند و از این رو پای ابزار کارآمد فشرده‌سازی به وسط خواهد آمد که نه تنها امکان ذخیره اطلاعات را با حجم کم فراهم می‌آورد، بلکه پزشک قادر خواهد بود اطلاعات تصویری را در مدت زمان کمتری از طریق سیستم‌های انتقال داده، ارسال نماید. ابزار کارآمد در این زمینه روشی خواهد بود که بتواند با درجه بسیار ناچیز اتلاف اطلاعات همراه باشد و نیز داده‌ها پس از فشرده شدن به سادگی به حالت انتشار (Decompression) درآیند. یک تصویر ماموگرافی ساده با عمق ۵۰ میکرومتر و دقت ۱۲ بیت، تقریباً نیازمند به ۳۸ مگابایت فضا جهت ذخیره شدن در فضای مانند

هاردیسک رایانه است [۷]. با وجود پیشرفت‌های بسیار زیادی که در حوزه تصویر برداری پزشکی صورت پذیرفته، اما هنوز هم مشکلاتی نظیر حجم زیاد تصاویر ذخیره شده و انتقال ناموفق داده‌های حجیم خود نمایی می‌کنند.

فشرده سازی یکی از فرایندهای ضروری و کارآمد در ذخیره سازی بهینه اطلاعات به حساب می‌آید که بر اساس آن می‌توان مخابره اطلاعات ضروری را تسهیل بخشید. این فرایند معمولاً از روش‌های متداول و مرسوم چون JPEG [۸]، JPEG-2000 [۹]، SPHIT [۱۰]، EBCOT [۱۱]، روش لیفتینگ [۱۲] و دیگر شیوه‌های قدیمی پیشنهاد شده در این زمینه استفاده می‌کند. در اصل می‌توان دو نوع کلی فشرده سازی را برشمرد: بی اتلاف و با اتلاف. الگوریتم‌های نمونه در این زمینه ترکیبی از تجزیه یک سیگنال هستند که توسط الگوریتم‌های چون فوریه یا موجک صورت می‌پذیرد. فرایند کوانتیزه کردن و کدینگ آنروپی یا کدینگ بی اتلاف نیز در این زمینه وجود دارد که دربردارنده روش‌های چون کدگذاری هافمن یا کدگذاری محاسباتی هستند. اخیراً محققین برخی روش‌های فشرده سازی تصاویر را با استفاده از شبکه‌های عصبی مصنوعی [۱۳] با تکیه بر الگوهای مختلف بکار گرفته‌اند که معمولاً رویه اصلی آن بهره‌گیری از طبقه‌بندی پیکسلی بر اساس یک بلوک از بخشی از تصویر می‌باشد [۱۷-۱۴]. جزئیات این تکنیک‌ها و نحوه پیاده‌سازی آنها را می‌توان در روش تحقیقی [۱۸] مشاهده نمود.

در مجموع در تکنیک‌های فشرده سازی مبتنی بر شبکه‌های عصبی، روش پس انتشار (BP) مورد استفاده قرار می‌گیرد. نگاشت سطوح خاکستری تصویر، تکنیک متفاوتی بوده که بر اساس آن همگرایی به خروجی مطلوب تا حد قابل ملاحظه‌ای افزایش یافته و عملکرد بهتری را نسبت به سایر روش‌ها دربردارد [۱۹]. برخی از محققین شبکه‌های عصبی مصنوعی را به مثابه رویه‌ای قابل اجرا بکار می‌برند که مطابق آن میزان خطا در زمان کوانتیزه نمودن به حداقل می‌رسد [۱۱ و ۲۰-۲۵]. از نگاشت Kohonen و نگاشت خود-سازمانده افزایشی در شبکه‌های عصبی برای اغلب تصاویر پزشکی استفاده شده و نتیجه گزارش شده از آن نیز تا حد قابل قبولی مناسب بوده است [۲۶].


در این مقاله، سیستم فشرده سازی جدیدی برای تصاویر پزشکی و به ویژه تصاویر ماموگرافی بر مبنای شبکه‌های عصبی مصنوعی پیشنهاد شده است. یادگیری شبکه عصبی مصنوعی پیشنهادی بر اساس الگوریتم L-M (Levenberg Marquardt) بوده و به همین دلیل فشرده سازی تصویر ماموگرافی نمونه تا حد چشمگیری با حداقل خطا و اتلاف اطلاعات همراه است. همچنین زمان لازم جهت فشرده سازی تصاویر پزشکی و به ویژه تصاویر ماموگرافی که با حجم و پیچیدگی بالا همراه هستند، در مقایسه با تکنیک‌های مشابه بسیار کمتر است.

۲-۲ شبکه‌های عصبی مصنوعی

یکی از ابزارهای مناسب در حوزه مهندسی که می‌تواند در کشف الگوهای پیچیده و مدلسازی سیستم‌های غیر-خطی کاربرد داشته باشد، شبکه‌های عصبی مصنوعی هستند که در سال ۱۹۴۳ توسط McClouth و Pitts با الهام از نرون‌های مغز انسان بصورت یک مدل ریاضیاتی پیشنهاد شد [۲۷]. همانند شکل ۱ (ج)، شبکه‌های عصبی مصنوعی، از ۳ لایه ورودی، خروجی و پنهان ساخته شده‌اند. بخش‌های در شبکه عصبی مصنوعی بنام نرون یا گره وجود دارند که کار پردازش اطلاعات را انجام می‌دهند. ارتباط بین نرون‌ها، لایه نام دارد و میزان تأثیر نرون‌ها را بر یکدیگر وزن لایه‌ها در نظر می‌گیرند و نیز یک مقدار ثابت به عنوان بایاس به هر لایه اضافه می‌شود. در شکل ۱ (الف)، لایه‌های ورودی، مخفی و خروجی این مدل ریاضیاتی مشاهده می‌شود. یکی از کاربردهای بسیار مهم شبکه‌های عصبی مصنوعی شبیه سازی فرایندهای است که می‌توان یک رابطه مستقل را بین ورودی و خروجی آن استنتاج نمود [۲۸]. با ضرب مقادیر ورودی در وزن‌های متناظر با آن، شبکه ورودی محاسبه می‌شود و این فرایند تا تحویل مقادیر به تابع فعال‌ساز تکرار خواهد شد. وزن روی یک شاخه از نرون نام که به نرون نام در لایه بعدی مرتبط می‌شود، با نام w_{ij} شناخته می‌شود. مقدار خروجی Y_j نرون نام توسط معادلات (۱) و (۲) محاسبه می‌شوند:

$$net_j = \sum_{i=0}^n w_{ij} x_i \quad (1)$$

$$Y_j = f_{act}(net_j) \quad (2)$$



شکل ۱ ساختار یک شبکه عصبی، (الف) یک سلول عصبی نمونه در بدن انسان، (ب) شبکه عصبی مصنوعی نیز با اعمال ورودی همانند یک سلول عصبی خروجی می‌دهد، (ج) توپولوژی یک شبکه عصبی

سازماندهی مقاله به این صورت است که در بخش دوم، مواد و روش‌های الگوریتم پیشنهادی معرفی می‌شوند. در بخش دوم، روش پیشنهادی که ترکیبی از ساختار شبکه عصبی مصنوعی مورد استفاده، الگوریتم Levenberg Marquardt و کدگذاری تصاویر ماموگرافی است، ارائه خواهد شد. در بخش سوم، نتایج عملی و یافته‌های کار عنوان می‌شوند و در بخش نهایی به بحث و تفسیر نتایج حاصله خواهیم پرداخت.

مواد و روش‌ها

۱-۲ داده‌های مورد بررسی

داده‌های مورد بررسی در این تحقیق از سطح سه کلینیک تصویربرداری که مجهز به یونیت ماموگرافی به همراه تیوب اشعه x، بازوی C شکل به منظور استفاده در بیوپسی و استیشن تشخیصی هستند، جمع آوری شده‌اند. تعداد تصاویر دریافتی ۱۲۸ تصویر با سطوح خاکستری (Gray-Scale) و با فرمت LJPEG از زنان با میانگین سنی $46/4 \pm 6/55$ سال و شاخص توده بدنی $23/6 \pm 5/78$ انتخاب شده است. برای اسکن بافت پستان در دستگاه رادیولوژی از اسکنرهای DBA، HOWTEK و LUMYSIS استفاده شده و تعداد بیت مورد نیاز جهت ذخیره سازی تصاویر ۱۲ و ۱۶ بیتی بوده و حجم هر یک از این تصاویر مابین ۸ تا ۵۰ مگابایت متغیر بود که جهت یکسان نمودن محاسبات، اندازه این تصاویر به ابعاد 32×32 ، 64×64 ، 128×128 و 256×256 تغییر یافتند. رزولوشن تصاویر ماموگرافی نمونه نیز یکی از مقادیر ۴۲، ۴۳/۵ و ۵۰ میکرون هستند.

و به همین ترتیب تابع گرادیان بر اساس ماتریس معادله (۹) بیان می‌گردد:

$$\nabla F(x) = 2J^T(x) v(x) \quad (9)$$

که در آن $J(x)$ را ماتریس ژاکوبین می‌نامند. در گام بعدی ماتریس هسینمورد توجه قرار خواهد گرفت و المان kj در ماتریس هسین بر اساس رابطه (۱۰) معرفی می‌شود:

$$[\nabla^2 F(x)]_{kj} = \delta^2 F(x) / \delta x_k \delta x_j \quad (10)$$

ماتریس هسین را می‌توان بر اساس ماتریس معرفی شده در (۱۱) تعریف نمود:

$$\nabla^2 F(x) = 2J^T(x) J(x) + 2S(x) \quad (11)$$

که در آن $S(x) = \sum_{i=1}^n V_i(x) \cdot \nabla^2 v_i(x)$ و با فرض آنکه $S(x)$ کوچک باشد، ماتریس هسین بر اساس رابطه (۱۲) تخمین زده می‌شود:

$$\nabla^2 F(x) \approx 2J^T(x) J(x) \quad (12)$$

با قرار دادن مقادیر $\nabla^2 F(x)$ و $\nabla F(x)$ روند گاوس-نیوتن را می‌توان شکل داد:

$$X_{k+1} = X_k - [J^T(X_k) J(X_k)]^{-1} J^T(X_k) V(X_k) \quad (13)$$

در این روند مشکلی که خودنمایی می‌کند آن است که $H=J^T J$ معکوس پذیر نیست و به همین دلیل از معادله (۱۴) برای حل این مشکل استفاده می‌شود:

$$G = H + mI \quad (14)$$

استفاده از این معادله سبب خواهد شد تا روند معادله L-M شکل گیرد که مطابق معادلات (۱۵) و (۱۶) بیان می‌شوند:

$$(15)$$

$$X_{k+1} = X_k - [J^T(X_k) J(X_k) + m_k I]^{-1} J^T(X_k) V(X_k) \quad (16)$$

$$(16)$$

$$\nabla X_k = -[J^T(X_k) J(X_k) + m_k I]^{-1} \times J^T(X_k) V(X_k)$$

۴-۲ ساخت مدل

الگوریتم پیشنهادی، دو گام اصلی دارد که در مرحله نخست، شبکه عصبی تغذیه شونده شکل می‌گیرد و سپس الگوریتم L-M جهت یادگیری شبکه عصبی مورد استفاده قرار خواهد گرفت. شکل ۲، نمایانگر بلوک دیاگرام روش پیشنهادی در فشرده سازی تصاویر ماموگرافی است. شبکه‌های عصبی چند لایه با الگوریتم پس انتشار می‌تواند بصورت مستقیم جهت فشرده سازی تصویری که در شکل ۳ به نمایش درآمده است، بکار رود. یک تصویر ماموگرافی مانند F به بلوک‌های پیکسلی R_{xc} تقسیم می‌شود.

که در آن net_j اتصال خطی هر یک از مقادیر x_i که در w_{ij} ضرب می‌شود، تعداد ورودی‌های متصل به نرون زام است و f_{act} تابع فعالسازی نرون زام است. توابع فعالسازی از لحاظ منطق ریاضیاتی (معمولاً تابع سیگموئید استفاده می‌شود) تابعی است که تانژانت هایپربولیک (Hyperbolic function) نام دارد که مطابق معادلات (۳) و (۴) معرفی می‌شوند:

$$Y_j = \frac{1 - \exp(-net_j)}{1 + \exp(-net_j)} \quad (3)$$

$$Y_j = \frac{1}{1 + \exp(-net_j)} \quad (4)$$

خروجی حاصل آمده شبکه با خروجی مطلوب مقایسه خواهد شد و خطا در هر بار حرکت از ورودی به خروجی برای هر نرون محاسبه می‌شود. بردار خطا یا E بین مقادیر مطلوب ورودی و خروجی شبکه مطابق با معادله (۵) تعریف می‌گردد:

$$E = \sum_j E_j = \sum_j \frac{1}{2} (T_j - Y_j)^2 \quad (5)$$

در این رابطه، T_j مقدار مطلوب یا هدف نرون خروجی زام است. خطاها در تمام لایه‌ها انتشار یافته‌اند و به این ترتیب می‌توان میزان خطا را برآورد نمود و در تکرار بعدی آنرا به حداقل رساند. این روش تا زمانی که همگرایی مطلوبی حاصل آید، ادامه می‌یابد و وزن شاخه‌ها در هربار تکرار فرایند برورسانی می‌شوند.

۲-۳ یادگیری شبکه عصبی با استفاده از الگوریتم L-M

الگوریتم Levenberg Marquardt (L-M) در اصل تغییرات تئوری نیوتن است که برای کمینه کردن توابع ریاضیاتی همانند مجموع مجذورات توابع غیر خطی دیگر مور استفاده قرار می‌گیرد. این کاربرد را می‌توان برای آموزش شبکه‌های عصبی استفاده نمود با این شرط که در شبکه‌های عصبی در زمان محاسبه خطای بازگشتی برای تنظیم وزن‌ها، بخش خطا بصورت مجذورات توانی در دسترس باشد. روند تئوری نیوتن برای بهینه سازی تابع نمونه $F(x)$ مطابق رابطه (۶) بیان می‌شود:

$$X_{k+1} = X_k - A_k^{-1} g_k \quad (6)$$

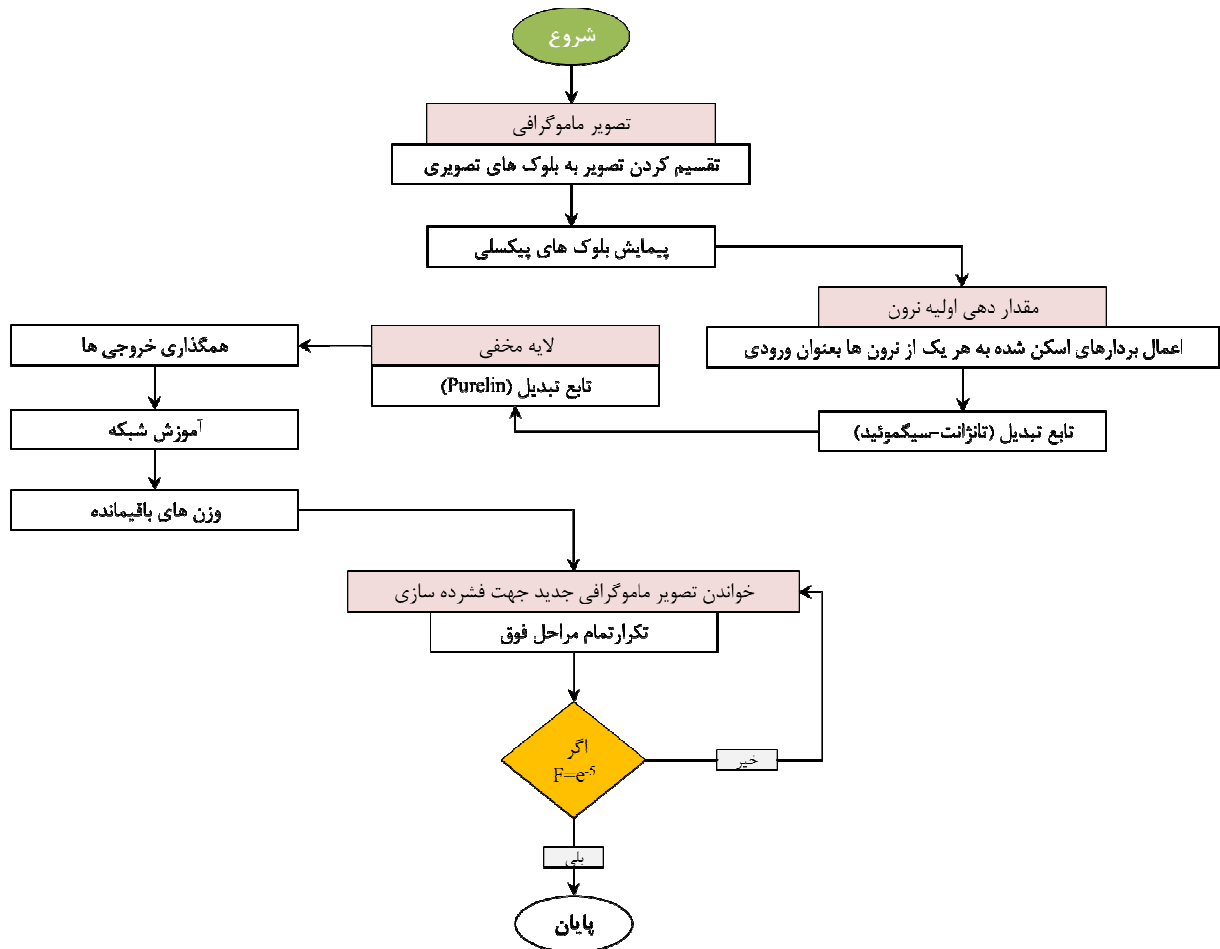
که در آن $A_k = \nabla^2 F(x)$ و $g_k = \nabla F(x)$. فرض بر آن است که $F(x)$ مطابق (۷) مجموع مجذور توابع فرض شود:

$$F(x) = \sum_{i=1}^n v_i^2(x) = V^T(x) v(x) \quad (7)$$

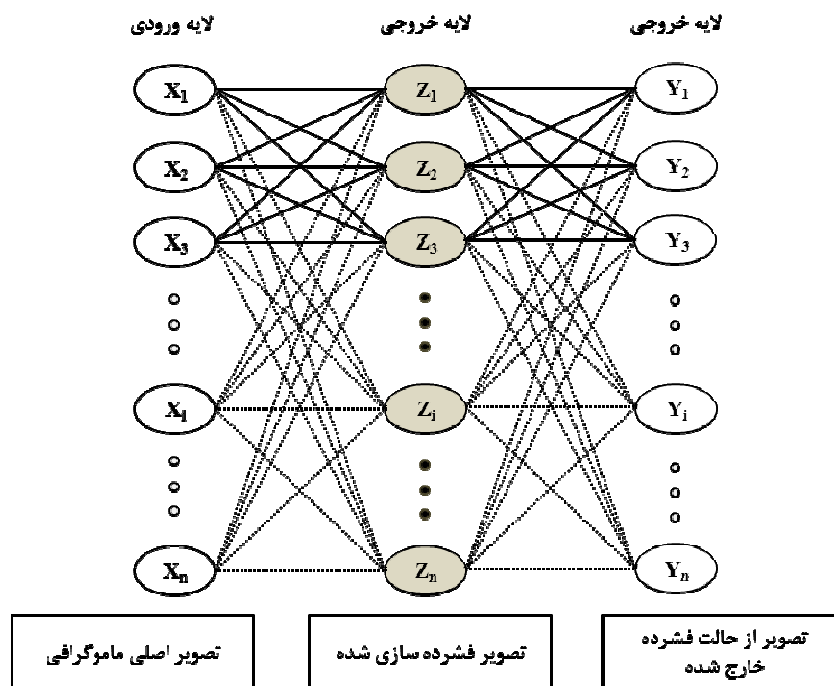
به این ترتیب المان زام گرادیان بصورت رابطه (۸) نشان داده می‌شود:

$$(8)$$

$$[\nabla F(x)]_j = \delta F(x) / \delta x_j = 2 \sum_{i=1}^n v_i(x) \delta v_i(x) / \delta x_j$$




شکل ۲ چارچوب روش پیشنهادی جهت فشرده سازی تصاویر ماموگرافی



شکل ۳ ساختار فشرده سازی تصاویر ماموگرافی با استفاده از لایه های ورودی، مخفی و خروجی شبکه عصبی پیشنهادی

پیشنهادی ساخته شده در محیط برنامه نویسی Matlab 8.1 به نمایش در آمده است که از الگوریتم L-M برای یادگیری شبکه استفاده می کند. در این شکل تعداد نرون های لایه های ورودی، مخفی اول، مخفی دوم و خروجی به ترتیب ۱، ۱۶، ۴ و ۱۶ می باشد.



شکل ۴ ساختار لایه ها و تعداد نرون های آنها با استفاده از برنامه نویسی محیط Matlab

نمایانگر تصویر کد شده H هستند که از طریق لایه خروجی عبور می کنند تا سیگنال خروجی یا $y(n)$ حاصل آید. سیگنال های خروجی با بلوک های تشکیل شده از تصویر ماموگرافی با $p = R_{xc}$ روی هم انباشته می شوند و در نهایت تصویر F_f که تصویر خروجی حاصل از بلوک کردن تصویر ماموگرافی است، حاصل می آید. می توان تمام مراحل تکرار یادگیری را بر اساس الگوریتم L-M در جدول ۱ خلاصه نمود:

تمام بلوک های تصویر اصلی از طریق لایه مخفی برای بدست آوردن سیگنال لایه مخفی عبور می کنند و این سیگنال $h(n)$ نامیده می شود و در بردارنده بلوک های کد شده تصویر ورودی یا همان $x(n)$ است. در صورتی که $L < P$ باشد، کد گذاری جهت فشرده کردن تصویر به وقوع می پیوندد. فرض بر آن است که لایه خروجی مرکب از نرون های $m = p = R_{xc}$ برای هر یک نیز L سیناپس داشته باشیم و این که متناسب با ماتریس وزنی خروجی انتخاب گردد. تمام بردار مخفی $h(n)$

جدول ۱ مراحل تکرار الگوریتم L-M که جهت آموزش شبکه عصبی از آن استفاده می شود

شروع

- ۱- اعمال تمام ورودی ها به شبکه
- ۲- محاسبه خروجی های متناظر شبکه و خطاها مطابق با معادله $e_q = t_q - a_q^M$
- ۳- محاسبه مجموع مجذور خطاها برای تمام ورودی ها یا $F(x) = \sum e_q^T e_q = \sum \sum (e_{j,q})^2 = \sum (v_i)^2$
- ۴- ماتریس ژاکوبین و حساسیت تکرار را محاسبه کن.
- ۵- مانریس های یکتا را در حساسیت های Marquardt کامل کن.
- ۶- محاسبه ΔX_k و ذخیره آن.
- ۷- محاسبه مجدد مجموع مجذور خطاها با استفاده از $X_k + \nabla X_k$.
- ۸- اگر مجموع مجذورات کوچکتر از مقدار محاسبه شده در مرحله ۱ باشد، μ را بر ν تقسیم کن.
- ۹- با فرض آنکه $X_{k+1} = X_k + \nabla X_k$ آنگاه به مرحله ۱ بازگرد.
- ۱۰- اگر از مجموع مجذورات کاسته نشود، آنگاه μ را در ν ضرب کن و آنگاه به مرحله ۶ برگرد.

پایان

۲-۵ آموزش شبکه

که در آن J ماتریس ژاکوبین بدست آمده از مشتق خطاست، μ یک عدد اسکالر و در نهایت E تابع خطا می باشد. در طول آموزش، اطلاعات از تصویر ماموگرافی در یک ساختار بصورت ماتریس های وزنی خروجی و لایه مخفی کد می گردد. فرض بر

شبکه پیشنهاد شده با استفاده از الگوریتم L-M آموزش می بیند. الگوریتم آموزش بر اساس دقت بالای آن در تخمین توابع مشابه کاربرد دارد. تطبیق مابین وزن ها و بایاس ها بر اساس تابع تبدیل (۱۷) انجام می پذیرد:

$$\Delta W_{ij} = -(J^T J + \mu I)^{-1} J^T E \quad (17)$$

بازسازی نام دارد که جهت بسط تصویر ماموگرافی از آن استفاده می‌شود و مطابق رابطه (۱۹) قابل بیان است:

$$Y = (W^y \cdot H), Y \rightarrow F \quad (19)$$

یافته‌ها

برای پیاده سازی الگوریتم‌های پیشنهادی از محیط برنامه نویسی Matlab استفاده شده است و فرایند فشرده سازی تصاویر ماموگرافی بصورت برون خطی (Off-line) انجام پذیرفت. الگوریتم پیشنهادی بر روی مجموعه ۱۲۸ تصویر ماموگرافی در دسترس که از ۳ کلینیک تخصصی از شهر سبزوار جمع آوری شده بودند، امتحان شد. جهت ارزیابی عملکرد سیستم پیشنهادی، مدل رفتاری الگوریتم بر اساس معیارهای سنجش با مقادیر واقعی مقایسه می‌شوند به این ترتیبکه خروجی‌های بدست آمده مورد تجزیه و تحلیل قرار می‌گیرند. الگوریتم فشرده سازی پیشنهادی بر یک نمونه ساده تصویر ماموگرافی اعمال شده و خروجی‌های آن در ۳ مرحله مجزا در شکل ۵ به نمایش درآمده است.


آن است که تصویر ماموگرافی F در آموزش بلوک‌های تصویری با ابعاد $R_x C$ و $R_y C$ استفاده شود. در گام نخست، ماتریس بلوکی F به ماتریس X با ابعاد $P \times N$ شامل بردارهای آموزش تبدیل می‌شود، $x(n)$ بر اساس بلوک‌های تصویر شکل می‌گیرد و به عبارت دیگر P برابر $r.c$ خواهد بود و همچنین $P.N = R_x.C$. داده‌های نهایی برابر داده‌ها قرار می‌گیرند به قسمی که $D=X$ باشد. پس از آن شبکه تا زمانی آموزش داده خواهد شد که میانگین مجذور خطاها یا MSE به اندازه کافی کوچک شود. ماتریس‌های W^y و W^h نیز در کد کردن و رمزگشایی بکار گرفته خواهند شد.

۲-۶ کدگذاری و رمزگشایی تصویر

بخش نخست لایه مخفی جهت کد کردن تصویر ماموگرافی استفاده می‌شود که بر اساس معادله (۱۸) بیان خواهد شد:

$$F \rightarrow X, H = (W^h \cdot X) \quad (18)$$

که در آن X تصویر کد شده F است. تصویر ماموگرافی با استفاده از قسمت دوم لایه مخفی رمزگشایی می‌شود و به عبارتی خروج از حالت فشرده‌گی را خواهیم داشت. این فرایند



شکل ۵ در این تصویر، رویه الگوریتم پیشنهادی بر یک تصویر ماموگرافی نمونه اعمال شده است، (a) تصویر ماموگرافی ورودی، (b) تصویر فشرده شده، (c) تصویر فشرده شده در تکرار ۵۰ ام و اختلاف آن و (d) تصویر فشرده شده در تکرار ۷۰ ام.

• **متوسط مجذورات خطا (MSE):** محاسبه میانگین خطای مابین تصویر اصلی و تصویر فشرده شده که مطابق با رابطه (۲۰) تعریف می‌شود:

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} |I(i,j) - K(i,j)|^2 \quad (20)$$

• **رابطه بیشترین نسبت تفاوت (PSNR):** این معیار اغلب برای اندازه گیری کیفیت یک تصویر در زمان فشرده کردن و بسط تصویر کاربرد دارد:

$$PSNR = 20 \log \left[\frac{255}{\text{Sqrt}(MSE)} \right] \quad (21)$$

به دلیل آنکه الگوریتم با برخی روش‌های مشابه در پژوهش‌های معتبر مقایسه می‌گردد، سه معیار برای تعیین عملکرد میزان کیفیت فشرده سازی در ارتباط با تصاویر گوناگون پیشنهاد شده است.

این سه محک عبارتند از: متوسط مجذورات خطا (MSE)، رابطه بیشترین نسبت تفاوت (PSNR) و زمان در معادله (۲۰)، I تصویر اصلی ماموگرافی ورودی و K تصویر فشرده شده است.

استفاده از سه محک MSE، PSNR و زمان بر هر گروه ۱۶ تایی از تصاویر اعمال می‌شود و برای ابعاد ۴ گانه تصاویر، الگوریتم مورد سنجش قرار می‌گیرد. میانگین عملکرد الگوریتم بر مجموعه ۱۲۸ تصویر ماموگرافی در جدول ۲ به نمایش درآمده است.

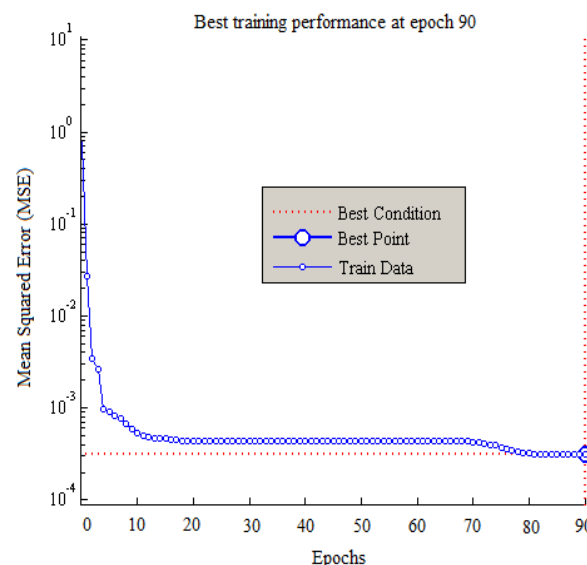

• **زمان:** فاکتوری که از اهمیت زیادی برخوردار است چرا که پزشک متخصص تمایل ندارد وقت زیادی را صرف فشرده سازی تصویر ماموگرافی کند. تصاویر در ۸ گروه تصادفی تقسیم می‌شوند و گروه‌های ۱ تا ۸ نامیده می‌شوند. سپس متوسط عملکرد الگوریتم با

جدول ۲ محک پارامترهای سه گانه فشرده سازی برای تصاویر ماموگرافی بر اساس دسته بندی در ۸ گروه تصادفی و ابعاد مختلف تصاویر

مجموع نهایی	ابعاد تصویر	گروه ۱	گروه ۲	گروه ۳	گروه ۴	گروه ۵	گروه ۶	گروه ۷	گروه ۸	میانگین	پارامتر محک
۴/۲۴	۳۲×۳۲	۲/۲۶	۲/۱۱	۲/۱۶	۳/۰۹	۳/۶۶	۲/۲۹	۲/۰۴	۲/۶۳	۲/۵۳	MSE
	۶۴×۶۴	۲/۹۶	۲/۵۱	۳/۷۲	۴/۶۵	۵/۹۶	۲/۸۱	۲/۲۳	۳/۱۶	۳/۵۰	
	۱۲۸×۱۲۸	۴/۶۳	۴/۴۳	۵/۳۵	۵/۸۸	۶/۳۹	۳/۴۹	۲/۷۸	۳/۳۱	۴/۵۳	
	۲۵۶×۲۵۶	۵/۸۳	۶/۵۷	۶/۲۲	۷/۱۲	۸/۲۹	۵/۳۱	۵/۱۹	۶/۷۰	۶/۴۱	
۳۳/۴۶	۳۲×۳۲	۳۷/۲۸	۳۸/۵۷	۳۷/۳۱	۴۱/۴۹	۳۴/۴۸	۳۶/۴۶	۳۴/۷۱	۳۹/۶۳	۳۷/۸۶	PSNR
	۶۴×۶۴	۳۴/۱۴	۳۶/۱۹	۳۳/۵۷	۳۸/۶۵	۳۶/۴۰	۳۳/۱۲	۲۹/۱۸	۳۶/۷۸	۳۴/۷۵	
	۱۲۸×۱۲۸	۳۳/۵۱	۳۴/۰۸	۳۲/۹۷	۳۵/۸۹	۳۲/۶۴	۳۱/۲۴	۲۹/۴۵	۳۰/۱۳	۳۲/۳۶	
	۲۵۶×۲۵۶	۳۱/۰۲	۲۹/۵۶	۲۹/۴۱	۲۹/۹۰	۲۸/۱۹	۲۷/۸۱	۲۶/۱۰	۲۸/۶۹	۲۸/۸۴	
۶۲/۶۲	۳۲×۳۲	۱۳/۳۲	۱۴/۷۳	۱۲/۴۷	۱۲/۶۳	۱۸/۳۲	۱۱/۱۸	۱۹/۷۱	۲۰/۱۲	۱۵/۳۱	Time
	۶۴×۶۴	۳۶/۴۸	۴۳/۱۴	۴۷/۱۵	۳۹/۲۰	۴۸/۹۶	۲۸/۱۶	۲۹/۵۶	۳۴/۵۵	۳۸/۴	
	۱۲۸×۱۲۸	۱۰۸/۸۴	۱۳۵/۷۳	۱۰۰/۱۶	۱۳۳/۶۶	۱۴۱/۷۱	۱۲۶/۷۰	۱۰۳/۹۳	۱۵۱/۱۴	۱۲۵/۲۳	
	۲۵۶×۲۵۶	۱۷۳/۲۶	۱۶۱/۳۶	۱۹۲/۲۳	۲۰۸/۷۷	۱۹۶/۱۱	۱۶۵/۹۸	۲۱۳/۱۲	۱۸۹/۸۳	۱۸۷/۵۸	

در زمان آموزش شبکه عصبی در تکرار ۹۰ام در شکل ۶ (سمت چپ) به نمایش درآمده است.


برآورد عملکرد روش پیشنهادی برای تصویر ماموگرافی شکل ۵ در شکل ۶ (سمت راست) به نمایش درآمده است. رگرسیون




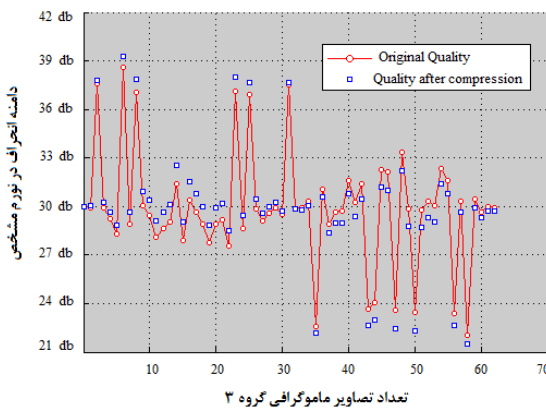

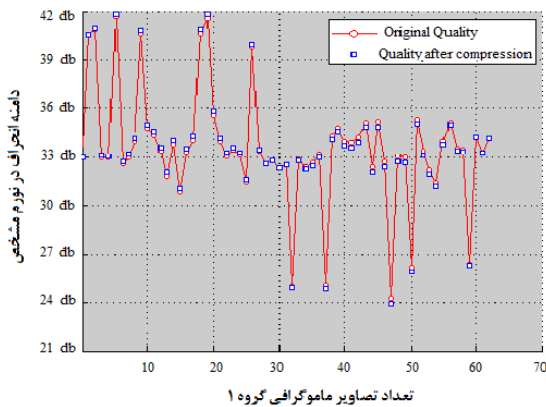
شکل ۶ روند آموزش تا زمانی که MSE به کمتر از 5×10^{-5} برسد (سمت راست) و رگرسیون شبکه عصبی مصنوعی برای تصویر ماموگرافی در شکل ۵ در تکرار ۱۷۲ام (سمت چپ).




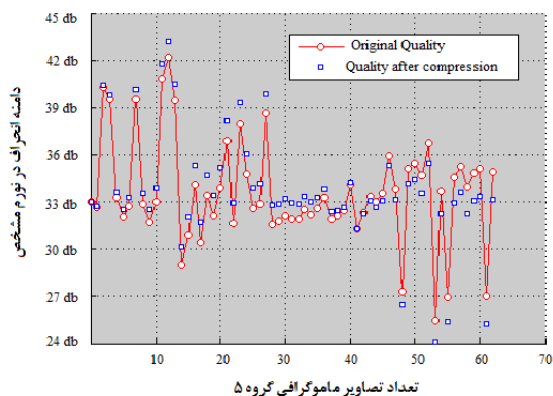
ماموگرافی پیاده سازی نمود... در شکل ۷ نمونه ای از یک تصویر ماموگرافی مشاهده می شود که فشرده سازی چند مرحله ای در آن به نمایش درآمده است. تقسیم بندی پایگاه داده مورد نظر بر اساس دسته بندی، ۸ گروه تصادفی و با ابعاد مختلف بود و به دلیل آنکه تصاویر به ابعاد چهارگانه تبدیل شدند، در مجموع، ۵۱۲ تصویر ماموگرافی حاصل آمد و رابطه بیشترین نسبت تفاوت (PSNR) بصورت نموداری در شکل ۸ به نمایش درآمده است.

نرخ فشرده سازی ۱:۸ برای سیستم در مقایسه با دیگر تکنیک های فشرده سازی تصاویر، نسبتی ایده آل به حساب می آید. ساختار پیشنهادی این امکان را فراهم آورده است تا میزان اتلاف اطلاعات نسبت به روش های مشابه بسیار کمتر و در حدود ۳٪ باشد و فرایند آموزش برای تصاویر با ابعاد 32×32 ، 64×64 ، 128×128 و 256×256 انجام شود. زمانی که صرف آموزش و تست شبکه عصبی مصنوعی می شود، زمانی قابل قبول است. از مزیت های دیگر این طراحی در آن است که می توان فشرده سازی چند مرحله ای را برای تصاویر



شکل ۷ تکرارهای مختلف بر کیفیت ذخیره سازی اثر دارد، (الف) تصویر اصلی با حجم ۷۸۰ کیلوبایت، (ب) تصویر فشرده شده در تکرار ۵ام، حجم ذخیره سازی ۸۰ کیلوبایت با PSNR برابر با ۱۷ دسی بل، (ج) تصویر فشرده شده در تکرار ۱۵ام، حجم ۱۶۷ کیلو بایت با PSNR برابر با ۲۸/۹ دسی بل، (د) تصویر فشرده شده در تکرار ۳۵ام، حجم ۴۸۰ کیلو بایت با PSNR برابر با ۳۴/۶۳ دسی بل و (ه) تصویر فشرده شده در تکرار ۵۱ام، حجم ۵۳۰ کیلو بایت با PSNR برابر با ۳۸/۱۳ دسی بل.





شکل ۸ بررسی وضعیت کیفیت تصویر در پیش از مرحله فشرده شدن و فشرده شدن در تکرار ۱۰۰ ام برای مجموعه ۵۱۲ تصویر. تصاویر ماموگرافی از بالا از چپ به راست معرف گروه‌های ۸ گانه می‌باشند و در هر گروه ۶۴ تصویر تحلیل شده که دایره قرمز کیفیت نخست و مربع آبی رنگ، کیفیت را پس از فشرده سازی آنها نشان می‌دهد

بحث نتیجه گیری

میان تمام روش‌ها ارائه می‌دهد و با اعمال آن به مجموعه تصاویر ماموگرافی نمونه، ضریب PSNR در سطح متوسط (در حدود ۳۱ دسی بل) حاصل آمد. یکی از معایب آشکار روش موجک در فشرده سازی در مقایسه با روش مورد بررسی در آن است که متوسط مجذورات خطاها بالاست و ضرایب آن در هر مرحله جهت کوانتیزه شدن به تخصیص بیت (Bit) نیاز دارند. روش دوم، تکنیک JPEG است که با وجود آنکه پردازش سریع و نسبت فشرده سازی بالایی را در اختیار کاربر قرار می‌دهد، اما در مقایسه با روش پیشنهادی MSE بالاتری دارد (در حدود ۲۵ تا ۳۵) و همانند روش موجک به ضرایب کوانتیزه کننده (مانند ضرایب تبدیل کسینوسی گسسته) به تخصیص بیت نیاز دارد. در مقابل این دو روش، روش کوانتیزه کردن برداری می‌تواند بصورت الگوی ساده پیاده سازی شود. همچنین به ضرایب کوانتیزه کننده نیاز ندارد، اما در مقایسه با روش پیشنهادی، PSNR کمتر (در حدود ۲۵ دسی بل) و MSE بالاتری را به همراه دارد. در کنار این تکنیک باید یک مرجع کد کننده وجود داشته باشد و به همین دلیل سرعت پردازش اطلاعات در فشرده سازی در قیاس با روش مورد استفاده در این مقاله کمتر است.

در زمینه فشرده سازی تصاویر ماموگرافی پژوهش‌های اندکی انجام شده که بصورت عملی قادر به پیاده سازی باشند و اغلب تکنیک‌های پیشنهادی در مجموع جهت فشرده کردن تصاویر غیر پزشکی کاربرد داشته‌اند. اما محققان بصورت عمومی در حوزه پزشکی به فشرده کردن تصاویر مختلف بافت‌های بدن پرداخته‌اند که از آن دسته می‌توان به تصاویر MRI، CT یا X-ray اشاره نمود. برای مقایسه عملکردی الگوریتم پیشنهادی در تصاویر ماموگرافی از مقایسه با روش‌های مبنای استفاده می‌شود که اغلب محققان با تکیه بر این تکنیک‌ها فرایند فشرده سازی تصاویر گوناگون را انجام می‌دهند. این تکنیک‌ها عبارتند از روش موجک [۲۴ و ۲۸]، روش JPEG [۸ و ۹]، روش کوانتیزه نمودن برداری [۲۰-۲۵ و ۲۹] و روش فراکتالی [۳۰]. هر یک از روش‌های پیشنهادی با معایب و مزایایی همراه هستند که از لحاظ ساختاری با سایر شیوه‌ها مقایسه می‌شوند. در عمل تکنیکی قابل قبول است که PSNR بالا و MSE کمی داشته باشد و از طرفی مدت زمان کمتری را صرف فرایند فشرده سازی کند. در مقایسه با تکنیک پیشنهادی مورد استفاده در این مقاله، روش موجک نسبت فشرده سازی بالاتری را در

سطح شهر سبزوار بود. نتایج بدست آمده از پیاده سازی الگوریتم پیشنهادی بر روی مجموعه داده‌ها، حاکی از عملکرد مناسب سیستم بود و محاسبه مولفه‌های چون PSNR و MSE در مقایسه با روش‌های مشابه که صرفاً در زمینه فشردن سازی تصاویر مختلف عملکرد دارند، چشمگیر و قابل توجه بود. نتایج عملی نشان می‌دهد که کیفیت تصویر ماموگرافی با وجود نسبت بالای فشردن سازی ۸:۱ تغییر محسوسی نداشته و به این ترتیب پزشک متخصص خواهد توانست تصاویر ماموگرافی را فشرده و آرشیو نماید. هدف آتی نویسندگان مقاله، کاستن از زمان صرف شده برای فشردن سازی تصاویر ماموگرافی و پزشکی و نیز ارتقاء بهینه‌تر فرایند فشردن سازی در تصاویر با حجم بالاتر خواهد بود.

تقدیر و تشکر

از همکاری پزشکان متخصص، جناب آقای دکتر محمدزاده، جناب آقای دکتر شهرآئینیو آقای ابارشی در مرکز آموزشی پژوهشی و درمانی امداد شهیددکتر بهشتی سبزوار صمیمانه سپاسگزاریم. این طرح از سوی دانشگاه حکیم سبزواری شهر سبزوار و دانشگاه علوم پزشکی سبزوار حمایت شده است.

References

- 1-LewinJM, HendrickER, D'OrsilCJ, et al. Comparison of full-field digital mammography with screen-film mammography for cancer detection: results of 4,945 paired examinations. *Radiology*. 2001 Mar; 218(3):873-80.
- 2-Vedantham S, Karellas A, Suryanarayanan S, D'Orsi CJ, Hendrick RE. Breast imaging using an amorphous silicon-based full-field digital mammography system: stability of a clinical prototype. *J Digit Imaging*, 2000 Nov; 13(4):191-9.
- 3-Niklason LT, Christian BT, NiklasonLE and et al. Digital tomosynthesis in breast imaging. *Radiology*. 1997 Nov; 205(2):399-406.
- 4-Suryanarayanan S, Karellas A, Vedantham S, Glick SJ, D'Orsi CJ, Baker SP, Webber RL. Comparison of tomosynthesis methods used with digital mammography. *AcadRadiol*. 2000 Dec; 7(12):1085-97.
- 5-Boone JM, Nelson TR, Lindfors KK, Seibert JA. Dedicated breast CT: radiation dose and image quality evaluation. *Radiology*. 2001 Dec; 221(3):657-67.
- 6-Chen B, Ning R. Cone-beam volume CT breast imaging: feasibility study. *Med Phys*. 2002 May; 29(5):755-70.
- 7-PerlmuterSM, CosmanPC, Gray RM, et al. Image quality in lossy compressed digital mammograms. *Biomed Imaging*, June 1997;59(2): 189-210.

فشردن سازی مبتنی بر فراکتال که عموماً برای تصاویر پزشکی کاربرد دارد، تکنیکی است که بر اساس محاسبات ریاضیاتی قابل فهم بنا شده و با وجود آنکه MSE کمی را ارائه داده، اما در کدگذاری اولیه کند است و PSNR خروجی آن هم در مجموع بالا نیست (در حدود ۳۰ دسی بل). بر پایه مقایسه جامع میان این روش‌ها و فشردن سازی مبتنی بر شبکه‌های عصبی، می‌توان به توانایی روش پیشنهادی در فشردن سازی چند مرحله‌ای اشاره نمود که عاملی با اهمیت و جدید به حساب می‌آید و بر اساس آن پزشک متخصص این امکان را خواهد داشت تا بر مبنای آن تصاویر با ظرفیت‌های متنوع و با کیفیت‌های گوناگون را داشته باشد. علاوه بر این موارد که مزیت‌های روش پیشنهادی محسوب می‌شوند، PSNR (در حدود ۳۴ دسی بل) روش مورد نظر مناسب است و همچنین متوسط مجدورات خطاها نیز در سطح پایینی قرار دارد.

در این مقاله، الگوریتمی جدید جهت فشردن سازی تصاویر ماموگرافی ارائه شد که بر اساس آن از شبکه‌های عصبی مصنوعی در فشردن سازی و بسط مجدد آنها با تکیه بر یادگیری ماشینی (الگوریتم L-M) استفاده شد. داده‌های مجموعه‌ای از ۱۲۸ تصویر ماموگرافی سه کلینیک تخصصی در

- 8-Wallace GK. The JPEG Still Picture Compression Standard. *IEEE Transactions on Consumer Elec*, 1992;38(1): 17-34.
- 9-UsevitchBE. A Tutorial on Modern Lossy Wavelet Image Compression: Foundations of JPEG 2000. *IEEE Sig ProcMag*, 2001; 18(5):22-35.
- 10-JyothswarJ, MahapatraS. Efficient FPGA implementation of DWT and modified SPIHT for lossless image compression. *J of Sys Arch*, 2007;53(7): 369-378.
- 11-TaubmannD. High performance scalable image compression with EBCOT. *IEEE Transactions on Image Processing*, 2000; 9(7): 1158-1170.
- 12-SrikalaP, Umar S. Neural Network Based Image Compression with Lifting Scheme and RLC. *Inter J of Res in Eng and Tech*, 2012; 1(1): 13-19.
- 13-RaoKR, Yip P. *Discrete Cosine Transform Algorithms, Advantages, Applications*. 1st ed. San Diego, CA, USA: Academic Press; 1990.
- 14-RaoPV, MadhusudanaS, NachikethSS, KeerthiK. Image compression using artificial neural network. *IEEE, ICMLC 2010*, p. 121-124.
- 15-DuttaDP, ChoudhurySD, HussainMA, MajumderS. Digital image compression using neural network. *IEEE, international Conference on Advances in*

- Computing, Control, Telecommunication Technologies, 2009, pp. 116 – 120.
- 16- DevarajSJ, EzraK, KasaraneniKK. Survey on Image Compression Techniques: Using CVIP Tools. *Advances in Computer Science and Information Technology. Computer Science and Information Technology Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering*, 2012; 86, pp 300-309.
- 17- Horng MH. Vector quantization using the firefly algorithm for image compression. *Expert Systems with Applications*, January 2012; 39(1): 1078–1091.
- 18- Egmont-Petersen M, RidderD, Handels H. Image Processing with Neural Networks – a review. *Pattern Recognition*, 2002; 35(10): 2279-2301.
- 19- Durai SA, SaroEA. Image compression with back-propagation neural network using cumulative distribution function. *World Acad. Sci. Eng. Technol.*, 2007;3(4): 60-64.
- 20- Hu YC, Chen WL, Lo CC, Chuang JC. Improved vector quantization scheme for gray-scale image compression. *Opto-Electronics Review*, June 2012, 20(2): 187-193.
- 21- Hosseini SM, Naghsh-Nilchi AR. Medical ultrasound image compression using contextual vector quantization. *Computers in Biology and Medicine*, 2012; 42(7): 743–750.
- 22- Al-Azawi S, Boussakta S, Yakovlev Alex. Image Compression Algorithms Using Intensity Based Adaptive Quantization Coding. *Am. J. Eng. Applied Sci*, 2012; 4(4): 504-512.
- 23- DokurZ. A unified framework for image compression and segmentation by using an incremental neural network. *Expert Systems and Applications*, 2008; 34(1): 611-619.
- 24- Lo SCB, Li H, Freedman MT. Optimization of wavelet decomposition for image compression and feature preservation. *IEEE Trans. Med Imaging*, 2003; 22(9):1141-1142.
- 25- Jiang J. Image Compression with neural networks–A survey. *Signal Processing: Image communication*, Elsevier Science B.V., 2000; 14(9): 737-760.
- 26- McCulloch W, Pitts W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 1943; 5(4):115 - 133.
- 27- Base AM, JanckeK, WismullerA, Foo S, MartinetzT. Medical image compression using topology-preserving neural networks. *Engineering Applications of Artificial Intelligence*, 2005; 18(4):383-392.
- 28- Said A, Pearlman WA. A new, fast, and efficient image codec based on set partitioning in hierarchical trees. *IEEE Trans. on Circuits and Systems for Video Technology*, 1996; 6(3): 243-250.
- 29- Chen YW. Vector Quantization by principal component analysis. M.S. Thesis, National TsingHua University, June, 1998.
- 30- Barnsley MF, Hurd LP. *Fractal Image Compression*. AK Peters, Ltd. Wellesley, Massachusetts, 1993.

Designing an Efficient Method of Multi-Stage Compression of Mammography Images for Optimal Storage, Transmission and LM Algorithm

Nosratinia.B¹, Haddadnia.J^{2*}

Submitted: 2014.11.4

Accepted: 2015.06.17

Abstract

Background: In the telemedicine process, using digital techniques in disease diagnosis caused to have felt needs of archiving and storing patient information and high bandwidth in data transfer.

Methods: This study aimed at introducing an efficient way of multi-stage compression of mammographic image data based LM algorithm and artificial neural networks. At First, data derived from mammographic images given to multi-layer neural network has achieved the possibility of forming with minimum damage and high degree of compaction in the first layer.

Results: The compression process of the mammography images was implemented using images of 128 women aged 46.41 ± 6.55 yrs with BMI 36.78 ± 5.5 from three specialized clinics in Sabzevar. The analysis yielded a mean square error (MSE) of 4.24 with the highest difference ratio of 33.46 and compression ratio of 8: 1 in the output of the algorithm. The system performance based on the accurate design of the software was acceptable therefore; it demonstrated high efficiency in practice.

Conclusion: The diagnosis in the discovery stage is highly consistent with the diagnosis in real based on reliability of software output in the compression and release, and considering the fact of mammographic images are not completely degraded during compression; therefore, this system has the capacity to be implemented achieving mammography images in hospitals and justify its application.

Keywords: Cancer, Breast prints, Image processing, Image compression and neural networks

¹ Electronic Engineering Master Student, Biomedical Engineering Group, Department of Electrical and Computer Engineering, Hakim Sabzevari University, Sabzevar, Iran.

² Assistance Professor in Biomedical and Electronic Engineering, School of Electrical and Computer Engineering, Hakim Sabzevari University, Sabzevar, Iran. (*Corresponding author), Address: Khorasan Razavi-Sabzevar-Hakim Sabzevari University- Electrical and Computer Engineering Group-Biomedical Group, Tel: +9851-44013587, +989151710649, Fax: +9851-44012174, Email: Haddadnia@hsu.ac.ir