

**إعادة بناء الصور الرقمية بتطبيق خوارزميات الاستيفاء
التقليدية وخوارزمية التعلم العميق**

اسيل ناجح عباس

إشراف الدكتورة زهرا قلج بيكئ

**الجامعة المستنصرية / كلية الإدارة والاقتصاد / شعبة تكنولوجيا
المعلومات**

**Prepared by the researcher: Aseel Najeh
Abbas**

**Supervised by: Dr. Zahra GHalag Begy
email address: al9625510@gmail.com**

ultra-high-resolution images is one of the most important goals of image processing that we will study in this paper, as we will propose a new algorithm that combines traditional interpolation algorithms with deep learning algorithm. Here, in this article, we will propose a new technique in order to achieve Super Resolution Reconstruction. This algorithm is a development of the traditional algorithms that work in this field, and its main dependence is a synthesis between the traditional algorithms based on interpolation and the deep learning algorithm. Keywords: image processing, super-resolution reconstruction, interpolation, deep learning, loss function


تعد إعادة بناء الصور فائقة الدقة أحد أهم أهداف معالجة الصور التي سندرسها في هذه الورقة، حيث سنقترح خوارزمية جديدة تجمع بين خوارزميات الاستيفاء التقليدية وخوارزمية التعلم العميق. هنا، في هذه المقالة، سوف نقترح تقنية جديدة من أجل تحقيق إعادة بناء فائقة الدقة. هذه الخوارزمية عبارة عن تطوير للخوارزميات التقليدية التي تعمل في هذا المجال، واعتمادها الرئيسي هو توليف بين الخوارزميات التقليدية القائمة على الاستيفاء وخوارزمية التعلم العميق. الكلمات المفتاحية: المعالجة التصويرية، إعادة البناء فائقة الدقة، الاستيفاء، التعلم العميق، تابع الخسارة

لطالما كان لمفهوم معالجة الصور دور كبير ومهم في العديد من التطبيقات الحياتية والعملية مثل الروبوتات، الذكاء الاصطناعي، المجالات العسكرية، أنظمة الأمن، وتطبيقات الفضاء، والأهم المجالات الطبية وتشخيص الأمراض. تعد إعادة بناء الصور فائقة الدقة أحد أبرز أهداف معالجة الصور والتي سندرسها في هذا البحث، حيث أننا سنقترح خوارزمية جديدة تجمع بين خوارزميات الاستيفاء التقليدية وخوارزمية التعلم العميق. هنا، في هذه المقالة سوف نقترح تقنية جديدة من أجل تحقيق إعادة بناء صورة فائقة الدقة، هذه الخوارزمية هي تطوير للخوارزميات التقليدية التي تعمل في هذا المجال واعتمادها الأساسي هو تركيب فيما بين الخوارزميات التقليدية المبنية على الاستيفاء وخوارزمية التعلم العميق. الإطار العام لهذه المقالة مقسم إلى جزأين رئيسيين. أولاً، يتم إجراء إعادة البناء العميق للبيانات منخفضة الدقة من خلال القدرة على التعلم العميق لاستخراج الميزات تلقائياً. بعد ذلك، بالدمج مع نتائج إعادة بناء الاستيفاء التقليدية، يتم استخدام خوارزمية التعلم العميق مرة أخرى للتدريب والتعلم، وفي النهاية يتم الحصول على البيانات عالية الدقة المعاد بناؤها. بعد ذلك سنتحقق من فعالية هذه التقنية من خلال تطبيق مجموعة من بيانات الاختبار عبر الإنترنت، وسنرى أن هذه الخوارزمية لها تأثير فعال على (MSE) (متوسط الخطأ التربيعي) أو (Main Square Error) ولها تأثير إيجابي على (PSNR) (النسبة بين ذروة الإشارة و التشويش) أو (Peak Signal-to-Noise Ratio). بالمقارنة بين الخوارزميات التقليدية وهذه الخوارزمية القائمة على التعلم العميق، سنرى أن تقنيتنا المقترحة لديها أداء أفضل في مجال المعالجة وإعادة بناء الصورة، وهي مثالية للحفاظ على الخطوط العريضة واضحة في الصورة وجودتها العالية. تتقسم خطة العمل في هذه المقالة على النحو التالي: يتضمن الفصل الأول مقدمة عن الصور الرقمية ومعالجتها. في الفصل الثاني، سنلقي نظرة على أحد أهم تطبيقات معالجة الصور الرقمية، وهو إعادة بناء الدقة الفائقة للصور، وسندرس الخوارزميات التقليدية التي تم تطويرها للعمل في هذا المجال. تتضمن التقنية خوارزمية تعتمد على الاستيفاء وخوارزمية أخرى تعتمد على التعلم العميق. في الفصل الثالث سنتنقل إلى طريقة مطورة تجمع بين الخوارزميتين أعلاه، وهي تقنية مقترحة لإعطاء نتائج أفضل على الصور عند تطبيقها على عينات الاختبار، وهذا ما سيتم عمله في الفصل الرابع. وأخيراً في الفصل الخامس ننتقل إلى ملخص الموضوع والاقتراحات والآراء.


الفصل الأول: مقدمة في مجال المعالجة التصويرية

الهدف الأساسي لإعادة بناء الدقة الفائقة للصور هو استخراج صورة عالية الدقة من صورة منخفضة الدقة، بمعنى آخر، لتحسين الصورة ذات المواصفات الرديئة والتفاصيل القليلة للحصول على صورة بها مزيد من التفاصيل (البيكسل) لاستخدامها في المجالات الطبية أو الأقمار الصناعية وأنظمة الأمان وحتى الكشف عن المعادن والتطبيقات الأخرى. باستخدام هذه الفكرة، يمكننا تكبير الصورة المحددة بحيث تبقى واضحة بأغلب تفاصيلها.

المعالجة التصويرية: في علوم الكمبيوتر، معالجة الصور الرقمية هي استخدام خوارزميات الكمبيوتر لإجراء معالجة على الصور الرقمية بطريقة تسمح لنا بإزالة تشويش الصورة أو ملاحظة تفاصيل أكثر بها بالإضافة للقدرة على إجراء تحولات هندسية (تغيير الحجم - الدوران وما إلى ذلك). الصور الرقمية: الصورة الرقمية هي في الواقع صورة تم تحويلها إلى مصفوفة باستخدام عملية النمذجة. في هذه الحالة، يمكن تحويل الصورة بواسطة الدالة ثنائية الأبعاد $f(x, y)$ الذي نسميه تابع التصوير، حيث x و y إحداثيات مكانية وقيمة f عند كل نقطة تسمى شدة سطوع الصورة في تلك الإحداثيات. بعبارة أبسط، نقول أن الصورة الرقمية هي في الواقع مصفوفة، حيث يتم وضع رقم بين 0 و 255 في كل خانة من هذه المصفوفة (التي نسميها بيكسل)، وهذا الرقم يشير إلى شدة سطوع ذلك البيكسل. نلاحظ في الشكل أناه تكوين الصورة الرقمية وقيم البيكسل المتراوحة بين 0 و 255



إذا كانت قيمة البيكسل 0 تكون شدة السطوح معدومة وهذا يعطي لوناً داكناً (أسود)، وإذا كانت قيمة البيكسل 255 (وأحياناً يُشار لها بـ 1) عندئذ يعطي لوناً فاتحاً (أبيض)، هذا يقودنا إلى ما يسمى بالصورة الثنائية (أبيض-أسود) التي قيمة البيكسل فيها هي 0 أو 1 فقط. الصورة الثنائية مهمة للغاية في العديد من تطبيقات معالجة الصور، من خلالها نحصل على معظم المعلومات المهمة للصورة، مثل عدد الجسيمات وخصائصها الهندسية. نلاحظ في الشكل أدناه توضيحاً للصورة الثنائية:




الفصل الثاني: إعادة البناء فائقة الدقة للصور

مع تقدم العلم، كانت هناك العديد من الطرق التي تتم بها معالجة الصور، خاصة في مجال إعادة بناء الصورة فائقة الدقة. في هذا الفصل، سوف ندرس الخوارزميات التقليدية التي تمت مناقشتها في مجال إعادة البناء فائقة الدقة للصور. تعتمد إحدى هذه الطرق أو الخوارزميات بشكل أساسي على الاستيفاء لمجموعة من النقاط ومن أهم أنواعها خوارزمية الاستيفاء الأقرب والاستيفاء الخطي والاستيفاء التكاملي، أما الخوارزميات الأخرى فهي قائمة على التعلم العميق والشبكة العصبية الالتفافية (CNN) أو (Convolutional Neural Network)، والتي سنشرحها بالتفصيل وبشكل واضح في هذا الفصل.

إعادة البناء فائقة الدقة للصور المبنية على الاستيفاء

يتم استخدام طريقة الاستيفاء لحساب قيمة نقطة من خلال الاستفادة من القيم المعروفة لمجموعة من النقاط المجاورة لتلك النقطة. سنبدأ بأبسط طريقة للاستيفاء، وهي خوارزمية استيفاء المجاورة الأقرب، تحدد هذه الطريقة ببساطة "أقرب" بكسل مجاور وتفترض قيمة شدته، بدلاً من حساب متوسط القيمة باستخدام بعض معايير الترجيح أو إنتاج وسيط القيمة بناءً على قواعد معقدة. على سبيل المثال، نرى في




الشكل أدناه مخطط لتأثير الاستيفاء الأقرب:

حيث أنه يتم في تحويل المجموعة تعيين النقطة A_0 إلى A_1 ، على أي حال، نظراً لأن النقطة A_1 تقع في موضع أحداثيات غير صحيح، عندئذ لا يمكن استخراج القيمة الرمادية للبيكسل، لذلك يمكن تقريب القيمة الرمادية لأقرب نقطة محاكاة A_2 على أنها القيمة الرمادية لـ A_0 . يتم اعتماد هذه الخوارزمية في العديد من برامج معالجة الصور وبرامج تحرير الصور مثل فوتوشوب، يمكننا أن نرى من النموذج أن حسابها بسيط ويمكن أن يعطي تأثيراً جيداً، لذلك تُستخدم هذه الخوارزمية على نطاق واسع في البرامج التجارية. لنفترض أن النقطة $A_0(x_0, y_0)$ في الصورة الأصلية التي قد تغير حجمها عند تطبيق مقياس ما a وأصبحت النقطة المقابلة لها في الصورة المكبرة هي $A_1(x_1, y_1)$ عندئذ يمكن التعبير عن العلاقة الرياضية التي تربط فيما بين $A_0(x_0, y_0)$ و $A_1(x_1, y_1)$ بالشكل:

$$\begin{bmatrix} x_1 \\ y_1 \\ 1 \end{bmatrix} = \begin{bmatrix} a & 0 & 0 \\ 0 & a & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_0 \\ y_0 \\ 1 \end{bmatrix}$$

$$\begin{bmatrix} (0, 0) \rightarrow (0, 0) \\ (0, 1) \rightarrow (0, 2) \\ (0, 2) \rightarrow (0, 4) \\ (0, 3) \rightarrow (0, 6) \\ (1, 0) \rightarrow (2, 0) \\ \dots \\ (3, 0) \rightarrow (6, 0) \\ (3, 1) \rightarrow (6, 2) \\ (3, 2) \rightarrow (6, 4) \\ (3, 3) \rightarrow (6, 6) \end{bmatrix}$$

النوع الآخر من الاستيفاء هو الاستيفاء الخطي الثنائي الذي يُعد أحد أساليب إعادة التشكيل الأساسية في الرؤية الحاسوبية وفي معالجة الصور، حيث يُسمى أيضاً بالترشيح الثنائي، تكمن فكرته الأساسية في استخدام قيم البيكسل للنقاط الأربعة المتجاورة $g(0.1)$ ، $g(1.0)$ ، $g(1.1)$ ، $g(0.0)$ حول الصورة الأصلية p لإجراء الاستيفاء الخطي في اتجاهي x و y كما هو موضح في الشكل أدناه.



خوارزمية الاستيفاء تستخدم دالة خطية متعددة التعريف لتقريب مساهمة القيمة الرمادية الخاصة بالنقاط الأربع المتجاورة للقيمة الرمادية من نقطة الاستيفاء الداخلية. يتم تعريف الدالة الخطية متعددة التعريف بالشكل:

$$w(t) = \begin{cases} 1 - |t| & 0 \leq |t| \leq 1 \\ 0 & \text{otherwise} \end{cases}$$

في الشكل السابق لنفترض أن Δx و Δy ، هي اسقاط من النقطة p إلى البيكسل $g(0.0)$ في الاتجاهين x و y على الترتيب، والمسافة بين وحدات البيكسل هي 1 عندئذ القيمة الرمادية لنقاط استيفاء p هي:

$$D_p = [\omega(\Delta x)\omega(1 - \Delta x)] \begin{bmatrix} D_{00} & D_{01} \\ D_{10} & D_{11} \end{bmatrix} \begin{bmatrix} \omega(\Delta y) \\ \omega(1 - \Delta y) \end{bmatrix}$$

حيث $D_{i,j}$ هي القيمة الرمادية للبيكسل $g(i,j)$.


إعادة البناء فائقة الدقة للصور المبنية على التعلم العميق

دقة أو جودة الصورة هي عدد وحدات البيكسل الظاهرة في كل بوصة مربعة PPI من الصورة الرقمية. تشير الدقة الفائقة (SR) إلى تحسين دقة الصورة (أو أي نوع من الإشارات حتى أنماط الفيديو) من خلال نظيرتها منخفضة الدقة (LR).

على سبيل المثال، عندما نقوم بتكبير صورة رقمية، نبدأ في رؤية الصورة تصبح ضبابية. هذا لأن كثافة البيكسل في المنطقة المكبرة هي مجرد استيفاء خطي لا يكفي لتصوير صورة واضحة. لطالما كانت تقنيات التعلم العميق عاملاً أساسياً في تحسين تقنية الدقة الفائقة نظراً لقدرتها على استخراج الميزات تلقائياً. ركزت الجهود الأخيرة حتى على تقليل الحاجة إلى الصور عالية الدقة كحقائق أساسية لتدريب الشبكات العصبية، حيث تكون الشبكة العصبية الالتفافية (CNN) عبارة عن شبكة عصبية تلقائية، يمكن لعصبها الاصطناعي أن يستجيب للخلايا العصبية الطرفية في نطاق تغطية جزئي ولديه أداء ممتاز في معالجة الصور الكبيرة. بالمقارنة مع الشبكات الأخرى، مثل (MLP) (Multilayer Perceptron) في [1]، أو (DBN) (Deep Belief Network) في [2]، تقلل CNN من تعقيد التعلم لأنها تحتوي على عدد أقل من المعلمات القابلة للتعديل وتتمتع بحالة مستقرة من التوسيع والتصغير والإمالة، وما إلى ذلك من التشوهات الأخرى التي تحدث في الصورة الرقمية. يمكن تصميم صورة منخفضة الدقة (LR) (Low Resolution) من صورة عالية الدقة (HR) (High Resolution) رياضياً، باستخدام دالة تدهور δ ومكون تشويش α على النحو التالي:

$$I_{LR} = \delta(I_{HR} \cdot \alpha)$$

حيث I_{LR} تمثل الصورة منخفضة الدقة و I_{HR} تمثل الصورة عالية الدقة. في طرق التعلم الخاضعة للإشراف، تهدف النماذج إلى تخريب الصورة عن قصد باستخدام المعادلة أعلاه واستخدام هذه الصورة المتدهورة كمدخلات للنموذج العميق والصور الأصلية كقاعدة حقيقية لـ HR . يؤدي هذا إلى إجبار النموذج على تعلم الانتقال بين صورة منخفضة الدقة ونظيرتها عالية الدقة، والتي يمكن بعد ذلك تطبيقها للتعامل مع أي صورة جديدة بشكل مثالي أثناء وقت الاختبار. يوضح الشكل أدناه بنية CNN التقليدية، والتي تتضمن طبقة الإدخال وطبقة الالتفاف وطبقة التجميع وطبقة الاتصال الكاملة وطبقة الإخراج.




إعادة البناء فائقة الدقة هي مسألة عكسية. بالنسبة للصورة منخفضة الدقة، قد يكون هناك العديد من الصور عالية الدقة المختلفة المقابلة لها. لذلك، عادةً ما يتم إضافة معلومات مسبقة لتطبيع حل الصور عالية الدقة. في الطريقة التقليدية، يمكن تعلم المعلومات من عدة أزواج من الصور منخفضة الدقة. تتعلم إعادة البناء فائقة الدقة القائمة على التعلم العميق بشكل مباشر تابع الانتقال من طرف إلى طرف من صورة عالية الدقة إلى صورة عالية الدقة من خلال الشبكة العصبية.

بالإلهام من الانتقال من طرف إلى طرف الخاص بالتشفير المتناثر، قام دونغ و مساعديه في [3] بتطبيق الشبكة العصبية المكونة من 3 طبقات للتعرف مباشرة على تعيين الميزات بين الدقة العالية والمنخفضة، واستخراج الميزات على التوالي بواسطة CNN وتنفيذها كانتقال خطي، وأخيراً نفذت إعادة البناء عالية الدقة. بالإضافة إلى ذلك، في السنوات الأخيرة، حققت نماذج الشبكة العصبية مثل ARCNN في [4] والشبكة العصبية المتبقية في [5] وخوارزمية VDSR في [6] استناداً إلى شبكة VGG نتائج إعادة بناء جيدة، ولكن العيوب تتمثل في عدد كبير من المعلمات والنموذج العالي تعقيد. من أجل حل هذه المشكلات، نقترح دمج خوارزمية الاستيفاء التقليدية مع نظرية التعلم العميق، واستخدام شبكة CNN البسيطة المكونة من ثلاث طبقات مع خوارزمية الاستيفاء لإكمال إعادة البناء فائقة الدقة، وتحقيق تأثير مثالي.

الفصل الثالث: دمج CNN مع خوارزمية الاستيفاء لإكمال إعادة البناء فائقة الدقة

بناءً على الشكل السابق، نجد أن في CNN التي استخدمناها خمس طبقات:

- الطبقة الأولى هي طبقة الإدخال، وحجم الصورة المدخلة هو $200 \times 300 \times 3$.
- الطبقة الثانية هي طبقة النمذجة (أخذ العينات) حيث تم اختيار هذه الطبقة لتحقيق تابع تكبير الصورة بحجم خطوة للنمذجة مساوي لـ 3 لتحقيق التضخيم في الصورة.
- الطبقة الثالثة هي طبقة التفاف، وحجم نواة الالتفاف 9×9 وعدد نوى الالتفاف هو 64.
- الطبقة الرابعة هي طبقة التفاف، وحجم نواة الالتفاف 5×5 وعدد نوى الالتفاف هو 32.
- الطبقة الخامسة هي طبقة التفاف وتمثل طبقة إخراج للشبكة حيث أن حجم نواة الالتفاف هو 5×5 . نظراً لأن بيانات التدريب الخاصة بالشبكة عبارة عن صور ملونة، فإن عدد نواة الالتفاف هو 3، وهي القنوات الثلاث للصورة الملونة (R, G, B) الأحمر والأخضر والأزرق. نرى في الشكل أدناه هيكل الشبكة التي تم اقتراحها

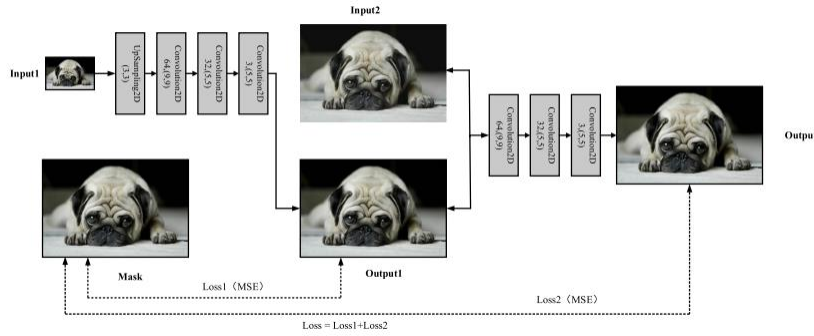


بالاقتران مع فكرة التعلم العميق، اقترحنا بنية إعادة بناء فائقة الدقة تجمع بين خوارزمية الاستيفاء و FCN (الشبكة العصبية الالتفافية بالكامل). تتعلم الشبكة مباشرة الانتقال بين الصور منخفضة الدقة وعالية الدقة من طرف إلى طرف، ولا توجد معالجة مسبقة ومعالجة لاحقة. أولاً، هيكلها

بسيط عن قصد، لكنه يوفر دقة أكبر من الأساليب المشابهة. ثانياً، من خلال المرشحات والطبقات المناسبة، يمكن تكبير الصورة، وستكون تفاصيل الصورة أكثر وضوحاً. تتطلب توابع انتقال التعلم من طرف إلى طرف تقدير مجموعة من معاملات الشبكة. يتم ذلك عن طريق تقليل الخسارة بين الصورة المعاد بناؤها $f(x)$ والصورة الحقيقية المقابلة $g(x)$ يتم ذلك باستخدام متوسط الخطأ التربيعي (MSE) كدالة خسارة لها الصيغة التالية:

$$L(\Theta) = \frac{1}{n} \sum_{i=1}^n \|f(x) - g(x)\|^2$$

حيث n يشير إلى عدد عينات التدريب، واستخدام MSE كدالة خسارة يفرضي إلى الحصول على نسبة عالية من النسبة بين ذروة الإشارة والتشويش (PSNR) وهو مؤشر إيجابي سيتم شرحه بالتفصيل في الفصل الرابع. نستخدم تابع Adam (تقدير اللحظة التكرارية) لتقليل خسارة إعادة البناء قدر الامكان، والتي تعدل تلقائياً معدل التعلم، وتتقارب بشكل أسرع، وتعمل بشكل أفضل في الشبكات المعقدة. من أجل تحسين تأثير إعادة البناء فائق الدقة، نقوم بدمج خوارزمية الاستيفاء التقليدية مع طريقة الالتواء الكامل ونقترح البنية الموضحة بالشكل أدناه



تتكون الشبكة من مدخلين، أحدهما للصورة منخفضة الدقة والآخر للاستيفاء. تضع الشبكة أولاً صوراً منخفضة الدقة، ثم تستخرج الميزات من خلال طبقة الالتفاف، ثم تجمع نتائج الإخراج مع الاستيفاء، ثم تستخرج الميزات من خلال طبقة الالتفاف. أخيراً، يتكون لدينا الإخراج عالي الدقة وصورة مكبرة. الجزء الأول هو إعادة البناء الأولية فائقة الدقة بنفس الطريقة التي طبقناها سابقاً. الجزء الثاني يجمع بين خرج الاستيفاء مع خرج الشبكة. كإخراج لهيكل الشبكة الثاني، يتضمن هذا الجزء ثلاث طبقات الالتفاف:

- حجم نواة الالتفاف هو 5×5 وعدد نوى الالتفاف هو 32.
 - حجم نواة الالتفاف هو 9×9 وعدد نوى الالتفاف هو 64.
 - حجم نواة الالتفاف هو 5×5 وعدد نوى الالتفاف هو 3، تعمل هذه الطبقة كإخراج للشبكة بأكملها.
- أما بالنسبة لدالة الخسارة فقد قمنا بتعيين اثنين من MSE كدوال خسارة معاً لتحسين بنية الشبكة.

$$L(\Theta) = \frac{1}{n} \sum_{i=1}^n \|f1(x) - g(x)\|^2 + \frac{1}{n} \sum_{i=1}^n \|f(x) - g(x)\|^2$$

حيث $f1(x)$ تشير إلى نتيجة إخراج الجزء الأول.

الفصل الرابع: النتائج التدريبية

في هذا الفصل، سنشرح أولاً أهم مفاهيم التقييم المستخدمة لإيجاد فعالية الطريقة المقترحة، ثم ننقل إلى دراسة عينات الاختبار العامة من الإنترنت التي سنستخدمها لاختبار النموذج المقترح. تم إجراء التجارب في PyCharm باستخدام منفذ keras و TensorFlow، مواصفات الكمبيوتر NVidia GeForce GTX 1070 GPU، ذاكرة 16 جيجا بايت، Inter (R) Core (TM) i7-8750H @ 2.20GHz، باستخدام 64 بت Win10.

معايير التقييم:

لا تكفي الإشارات المرئية لتقييم ومقارنة أداء طرق SR المختلفة لأنها نسبية للغاية بطبيعتها لذلك نحتاج لمعيار عالمي لأداء SR لمقارنة النماذج بطريقة عادلة. تعد نسبة الإشارة الضوضاء إلى التشويش (PSNR) ومؤشر الخطأ المربع الرئيسي (MSE) أكثر مقاييس التقييم شيوعاً لتقييم أداء SR. يمثل MSE الخطأ التربيعي التراكمي بين الصورة المضغوطة والصورة الأصلية، ولا توجد قيمة صحيحة لـ MSE. ببساطة،


كلما انخفضت القيمة كلما كان ذلك أفضل والقيمة 0 تعني أن النموذج مثالي. إذا كان حجم X و Y لمداخلات صورتين يتم المقارنة بينهما كلاهما $H \times W$ ، فإن MSE لها الصيغة التالية:

$$MSE = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W (X(i, j) - Y(i, j))^2$$

حيث $X(i, j)$ هي قيمة البيكسل للصف i والعمود j للصورة المدخلة؛ $Y(i, j)$ هي قيمة البيكسل الواقع في الصف i والعمود j للصورة الناتجة؛ H و W هما ارتفاع الصورة وعرضها. أما بالنسبة لمعيار التقييم الثاني PSNR، تعتبر نسبة الإشارة الضوئية إلى التشويش مقياساً موضوعياً يقيس جودة إعادة بناء الصورة من ناحية الحفاظ على تفاصيل الصورة. رياضياً يتم تعريفه بالصيغة التالية:


$$PSNR = 10 \log_{10} \left(\frac{(2^n - 1)^2}{MSE} \right)$$

يوضح الشكل في الأسفل عملية التعلم لدالة الخسارة في عملية التدريب. حيث أنه بزيادة عدد التكرارات، يستمر MSE في الانخفاض ويميل في النهاية إلى أن يكون مستقرًا، وهذا يعطي مؤشراً إيجابياً لأن الانخفاض في الخطأ هو دليل على فعالية الطريقة وأن الصورة المستخرجة متشابهة قدر الإمكان مع الصورة الأصلية.



سنقوم الآن بتطبيق مجموعة من التجارب بالاعتماد على الأساليب أو الخوارزميات المتخصصة في إعادة بناء الصورة الرقمية، ثم نقوم بإجراء مقارنة بناءً على رؤيتنا البشرية أولاً وثانياً قيم PSNR و MSE.

قمنا أولاً بمعالجة مجموعة الاختبار باستخدام أقرب خوارزمية الاستيفاء لأقرب مجاورة، ونظهر النتائج التجريبية في الشكل أدناه



حيث $A1$ و $B1$ عبارة عن صور إدخال، $A2$ و $B2$ صورتان حقيقتان، $A3$ و $B3$ هي صور مكبرة إذا أردنا الاعتماد على وجهة نظرنا البشرية المباشرة لتقييم خوارزمية الاستيفاء، فإننا نلاحظ من الشكل كطريقة إعادة بناء تقليدية فائقة الدقة، لا تحافظ على تفاصيل الصورة جيداً، والتفاصيل الرئيسية غير واضحة. ولكن إذا أردنا تقييمه بناءً على معايير التقييم الموضحة سابقاً MSE و PSNR، فلنلق نظرة على الجدول التالي:

	MSE	PSNR
A3	0.01019	19.9144
B3	0.00478	23.2028


يمكن أن نرى من الجدول أن PSNR للصورتين منخفض جداً، وهي علامة سلبية تشير إلى أن تأثير المعالجة ليس مثالياً للغاية. لنرى الآن مدى كفاءة وفعالية خوارزمية التعلم العميق مقارنة بالخوارزميات التقليدية القائمة على الاستيفاء من خلال تطبيق خوارزمية إعادة بناء فائقة الدقة المبنية على FCN (شبكة عصبية التلافيف بالكامل)، نلاحظ الشكل التالي:



وجداول التقييم المرافق بالشكل التالي:

	MSE	PSNR
A3	0.007451	21.2775
B3	0.002189	26.59621

إذا قمنا بمقارنة النتائج التجريبية لخوارزمية التعلم العميق مع نتائج الاستيفاء السابقة نلاحظ بوضوح أنه تم تحسين MSE و PSNR للصورتين، مما يثبت أن خوارزمية التعلم العميق لديها القدرة على الحصول على إعادة بناء فائقة الدقة بشكل أفضل وفي الوقت نفسه، يمكن أن تحقق خوارزمية التعلم العميق تأثيرات واضحة من خوارزمية الاستيفاء التقليدية. برؤيتنا البشرية، يمكن ملاحظة أن نهج التعلم العميق يحافظ على تفاصيل الصورة بشكل مثالي نسبياً. الآن لنرى النتائج التجريبية لطريقتنا المقترحة وتأثيرها على الصورة المُعالجة حيث أنها تعتمد على دمج فيما بين خوارزمية الاستيفاء وخوارزمية التعلم العميق:



تُظهر النتائج التجريبية أنه تم تحسين MSE و PSNR بطريقتنا المُقترحة، والتأثير واضح، والذي يمكن أن يوضح فعالية خوارزمتنا.

	MSE	PSNR
A3	0.00709	21.4893
B3	0.00200	26.9799

الفصل الخامس: خاتمة الموضوع هزايا ومقترحات

خلاصة الموضوع، سنذكر بإيجاز مزايا هذه الخوارزمية المُقترحة وبعض الاقتراحات التي يمكن أن تجعلها أفضل وأفضل، من أجل الحصول على تأثير إعادة بناء أفضل، يقدم نموذج FCN في هذا البحث طريقة الاستيفاء التقليدية في الشبكة لتسريع سرعة التقارب وتحسين جودة إعادة البناء مع تقليل معلمات الشبكة. ميزتها الرئيسية هي أن الخوارزمية المُقترحة لا تحتاج إلى إجراء الاستيفاء والتضخيم وعمليات المعالجة المسبقة الأخرى للصور منخفضة الدقة ليتم إعادة بنائها قبل الإدخال، ويمكن للشبكة معرفة المزيد من الميزات التفصيلية للصور باستخدام الانتعاف لإكمال أخذ العينات. مقارنة بالخوارزميات الأخرى، أظهرت النتائج التجريبية أن هذه الخوارزمية متقدمة وفعالة. في البحث المستقبلي، تتجسد اقتراحات التحسين في محاولة إجراء مزيد من البحث حول جوانب مثل تقليل معلمات النموذج، وتحسين قابلية النقل مع ضمان جودة إعادة البناء، من أجل تحقيق مهمة إعادة البناء على الجهاز المضمن بذاكرة محدودة ولكن مع سرعة تشغيل سريعة وهذا ما يجعل هذه الخوارزمية أفضل وأكثر عملية.

المصادر:

- [1] - G. Panchal, A. Ganatra, Y. P. Kosta, and D. Panchal, "Behaviour analysis of multilayer perceptrons with multiple hidden neurons and hidden layers," Int. J. Comput. Theory Eng., vol. 32, pp. 332–337, Apr. 2011.
- [2] - . Dedinec, S. Filiposka, A. Dedinec, and L. Kocarev, "Deep belief network based electricity load forecasting: An analysis of Macedonian case," Energy, vol. 115, pp. 1688–1700, Nov. 2016.
- [3] - C. Dong, C. C. Loy, K. He, and X. Tang, "Image super-resolution using deep convolutional networks," IEEE Trans. Pattern Anal. Mach. Intell., vol. 38, no. 2, pp. 295–307, Feb. 2014.
- [4] - C. Dong, Y. Deng, C. L. Chen, and X. Tang, "Compression artifacts reduction by a deep convolutional network," in Proc. IEEE Int. Conf. Comput. Vis., Dec. 2015, pp. 576–584.
- [5] - Y. N. Wang, P. L. Qin, and C. P. Li, "Improved algorithm of image super resolution based on residual neural network," J. Comput. Appl., vol. 22, no. 1, pp. 246–254, 2018.
- [6] - J. Kim, J. K. Lee, and K. M. Lee, "Accurate image super-resolution using very deep convolutional networks," in Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR), Jun. 2016, pp. 1646–1654.
- [7] - Y. Li, M. Paluri, J. M. Rehg, and P. Dollar, "Unsupervised learning of edges," in Proc. IEEE Conf. Comput. Vis. Pattern Recognit., Jun. 2016, pp. 1619–1627.