

インパルス性雑音除去への深層学習の応用に関する検討

天利 安志¹ 宮崎 敬^{1,a)} 村上 舜¹ 越村 勇介¹ 横山 靖樹¹ 山本 博章²

概要: 近年, デジタルカメラに用いられる CMOS イメージセンサの高解像度化に伴い, 受光部の単位面積当たりの入射光量の減少により, 光量のわずかな変動がインパルス性雑音の発生に影響する。これまで, MF(メジアンフィルタ)法などの雑音除去手法によって画質の向上がなされてきた。最近, ガウス性雑音やバースト雑音に対して深層学習を応用した雑音除去方法が提案され, 有効性が示されている。本稿では, この深層学習を用いたインパルス性雑音除去方法について検討を行い, その結果を報告する。特に, 損失関数を変えた時および Squeeze-and-Excitation block を用いた時の結果画像の画質への影響を調べた。また, ガウス性雑音に対する有効性を調べた。

A Study on Impulse Noise Removal with Deep Learning

YASUSHI AMARI¹ TAKASHI MIYAZAKI^{1,a)} SHUN MURAKAMI¹ YUSUKE KOSHIMURA¹
YASUKI YOKOYAMA¹ HIROAKI YAMAMOTO²

Abstract: As camera resolution progresses to higher resolution, a slight variation in light amount affects the generation of impulse noises due to decrement in the amount of incident light per unit cell of the light receiving area. So far, image quality has been improved by noise removal methods such as Median Filter (MF). Recently, a noise removal method applying Deep Learning to gaussian noise and burst noise has been proposed, and its effectiveness has been shown. In this paper, we investigate impulse noise removal method with Deep Learning and report the results of removed images using proposed method. In particular, we investigated the effect on the image quality of the result image when changing the loss function and using Squeeze-and-Excitation block. In addition, we examined the effectiveness of the proposed network against gaussian noise.

1. はじめに

CMOS や CCD によるイメージセンサによって得られる画像は, 画像センサのばらつき, 低照度化における撮像, センサの高解像度化による受光セル間の感度のばらつきなどにより, デジタル画像に雑音加わる。デジタル画像に加わる雑音の一つにインパルス性雑音が挙げられる。インパルス性雑音は, 画像上の不規則な場所に発生し, 雑音の濃度値の振幅が大きいという特徴がある。このインパルス性雑音を除去する有効な方法としてメジアンフィルタ (MF) 法が有効であるとされている [1]。しかし, MF 法

は, 画像の全ての画素に処理を適用するため, 雑音でない画素にも雑音除去処理を適用し, 画質を劣化させるという問題がある。この問題を改善するため, スイッチング型の雑音除去フィルタを用いたスイッチングメジアンフィルタ (SMF) が提案された [2], [3], [4], [5]。この SMF 法は, 走査中の注目画素が雑音か非雑音か判定し, 雑音と判定された画素のみ MF 処理を行う。そのため, MF 法で生じる非雑音画素の劣化を抑制することができ, 雑音除去とエッジの保存の両立ができる。しかし, SMF 法の多くは, 雑音検出および除去においてアルゴリズムを複雑化する傾向にあり, MF 法よりも処理時間がかかる傾向にある。そこで, 我々は 2×2 画素の雑音検出オペレータを用いた, 多方向走査と平均処理の 2 ステップ方式で雑音除去を行う多方向スイッチングメジアンフィルタ (多方向 SMF) 法を提案した [6]。

¹ 長野工業高等専門学校
National Institute of Technology, Nagano College

² 信州大学 工学部
Faculty of Engineering, Shinshu University

a) miya@nagano-nct.ac.jp

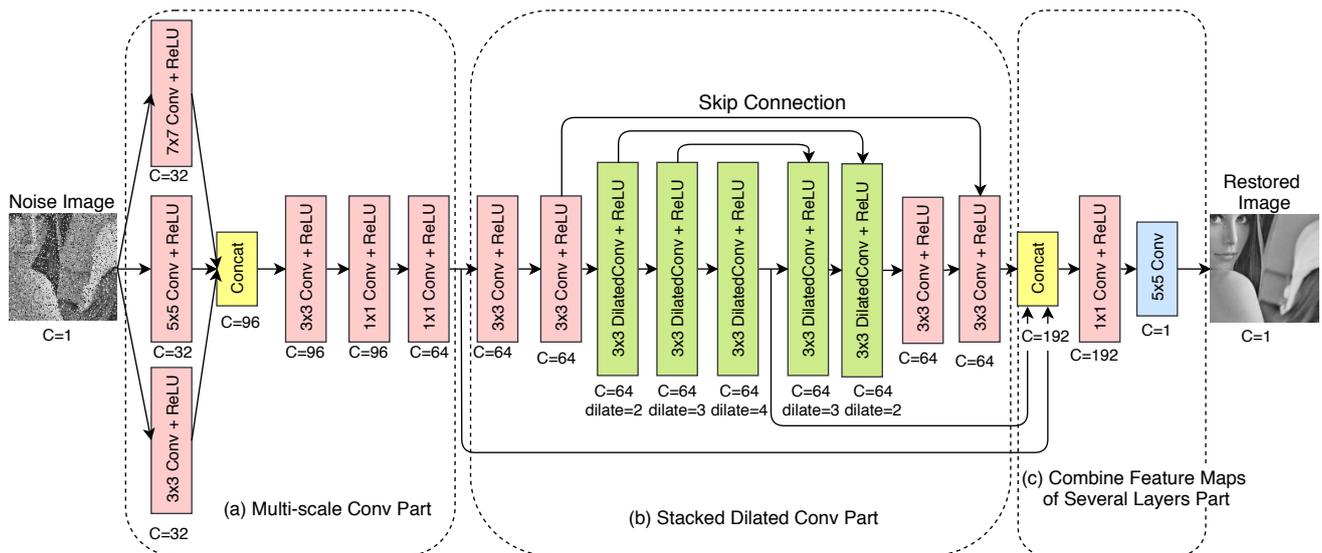


図 1: 提案ネットワークの構造

SMF 法や多方向 SMF 法というスイッチング型の手法では、注目画素が雑音か非雑音かの判定にしきい値を必要とする。しかし、画像ごとの最適なしきい値が異なるため、それぞれの最適なしきい値を求めることは難しく、その決定方法について現在も研究が進められている [7]。

本稿では、画像処理分野を中心にその著しい効果を示しつつある深層学習を用いることで、しきい値を必要としないインパルス性雑音除去への応用を行う。その中で、損失関数を変えた時ならびに Squeeze-and-Excitation block[28] を用いた時の結果画像の画質への影響を調べた。

2. 関連研究

画像に含まれる雑音の除去についての研究は古くから行われており、1章で述べたようなフィルタリング法のほかに、スパースコーディング [10]、ウェーブレット・ドメイン処理 [9]、3D 変換領域フィルタリング (BM3D) [12]、重み付き核ノルム最小化 (WNNM) [13]、などの様々な方法が提案されてきた。また、2008 年頃から、Convolutional Neural Network (CNN) に基づく雑音除去方法が提案され [11]、それ以来、TNRD[14] や DnCNN[15]、RED30[16] といった方法が提案されてきた。最近では、入力に調整可能な雑音レベルマップを用いる FFDNet[17] や、バースト雑音に対して、画素単位の雑音除去カーネルを予測する KPN[18]、未知の雑音に対し、GAN を用いて雑音サンプルを作成し、訓練データセットを構築し学習を行う GCB[19]、雑音画像のみを用いて学習を行う Noise2Noise[20] といった様々な方法が提案されている。

3. 検討モデル

3.1 インパルス性雑音モデル

インパルス性雑音除去の研究において、使用されるイン

パルス性雑音モデルは、ごま塩雑音とランダム値雑音の二種類ある。本稿では、濃度階調の最大値と最小値のみを用いるごま塩雑音よりも現実的な雑音を想定し、信号伝送時の任意の座標のビットエラーを想定するランダム値雑音を使用する。雑音の割合を P_{NR} 、原画像の信号値を $X_{i,j}^*$ 、劣化画像の信号値を $X_{i,j}$ とした時のランダム値雑音を次式で表す。

$$X_{i,j} = \begin{cases} X_{i,j}^* & \text{with probability } 1 - P_{NR} \\ h & \text{with probability } P_{NR} \end{cases} \quad (1)$$

ここで h は雑音であり、濃度値の範囲 $[0, 255]$ の間から一様に生成した整数の乱数値である [8], [21]。

3.2 ネットワーク構造

提案するネットワークの構造を図 1 に示す。提案ネットワークは主に Convolution 層とフィルタの間隔を広げることで局所受容野を拡大できる Dilated Convolution 層 [22] で構成し、各ブロックの下部の“C”はそれぞれのブロックの出力の特徴マップの次元数を示している。全ての Convolution, Dilated Convolution 層のストライドは 1 とし、それぞれの層で、入力特徴マップと出力特徴マップのサイズが同じになるようなゼロパディングを使用した (カーネルサイズが 1×1 の時は使用しない)。RED30[16] では、Skip Connection を用いることで、ネットワークが深くなるにつれて勾配消失がおり、学習が困難になる問題と深い層では画像の詳細が失われるという問題を解決した。我々はこれを参考にし、図 1 の (b) のように Skip Connection を用いた。活性化関数には Rectified Linear Unit (ReLU) [23] を用いた。提案ネットワークの特徴は以下の通りである。

- 入力画像に対して複数のカーネルサイズ (3×3 , 5×5 , 7×7) の Convolution 層を採用することで、複数スケールの特徴抽出を行なう。なお、これは GoogleNet[24]

の Inception モジュールを参考にした。

- (b) の部分で、フィルタの間隔を変えた 5 つ Dilated Convolution 層を採用することで、広範囲の領域を考慮した畳み込みを行う。
- (c) の部分で、3 つの異なる層の特徴マップをマージし、復元する。

4. 損失関数に関する検討

本章では、ネットワークにおける、損失関数の検討し、その結果を報告する。

4.1 損失関数

我々の損失関数は、ネットワークの出力画像と原画像を以下の式で表される L_1 誤差と L_2 誤差を用いて比較した。

$$L(\theta) = \frac{1}{N} \sum_{i=1}^N \alpha_1 \|f(\mathbf{x}_i; \theta) - \mathbf{y}_i\| + \alpha_2 \|f(\mathbf{x}_i; \theta) - \mathbf{y}_i\|^2 \quad (2)$$

ここで、 θ はネットワークのパラメーターであり、 $\{(\mathbf{x}_i, \mathbf{y}_i)\}_{i=1}^N$ は、 N 個の雑音画像-原画像ペアの学習サンプル、 $f(\mathbf{x}_i; \theta)$ はネットワークの出力画像を表す。また、 α_1 は $0 \leq \alpha_1 \leq 1$ 、 α_2 は $0 \leq \alpha_2 \leq 10$ とし、この α_1, α_2 の値を変え、実験を行なった。 α_1, α_2 の値は以下の通りである。

- $\alpha_1 = 1, \alpha_2 = 0$ (L_1 のみ)
- $\alpha_1 = 0, \alpha_2 = 1$ (L_2 のみ)
- $\alpha_1 = 1, \alpha_2 = 1$ ($L_1 + L_2$)
- $\alpha_1 = 1, \alpha_2 = 10$ ($L_1 + L_2 \times 10$)
- 初期値が $\alpha_1 = 1, \alpha_2 = 0$ で、25 epoch 毎に α_2 に 1 を加算し、 $\alpha_2 = 10$ となった時点で固定 ($L_1 + schedule L_2$)
- 初期値が $\alpha_1 = 1, \alpha_2 = 0$ で、25 epoch 毎に α_1 を 0.1 ずつ減算、 α_2 に 1 を加算し、 $\alpha_1 = 0, \alpha_2 = 10$ となった時点で固定 ($schedule(L_1 + L_2)$)

4.2 実験方法

4.2.1 使用したデータセットとネットワーク学習

ネットワークを学習するにあたり、ImageNet から無作為に 256×256 画素の画像を 13,000 枚収集し、これを訓練データ (10,400 枚) とテストデータ (2,600 枚) に分ける。次に、これらの画像を 8bit グレースケール画像に変換し、1 枚あたり 4 分割 (128×128 画素) した。その後、分割した画像に対して、10%, 20%, 30%, 40%, 50% の 5 つの割合でランダム値雑音を加え、雑音画像とそれに対応する原画像のペアを訓練データは 41,600 個 (一雑音付加率あたりのペア数は 8,320 個)、テストデータは 10,400 個 (一雑音付加率あたりのペア数は 2,080 個) 作成し、学習データセットとする。また、正規化として、各画素を 255 で除算し、データの値が 0.0~1.0 の範囲に収まるようにした。



図 2: 評価画像

表 1: それぞれの損失関数時の評価画像における平均 PSNR の比較

損失関数	雑音付加率				
	10%	20%	30%	40%	50%
L_1 のみ	36.39	33.18	30.50	28.53	26.72
L_2 のみ	36.36	33.30	30.78	28.74	26.94
$L_1 + L_2$	36.40	33.12	30.55	28.59	26.87
$L_1 + L_2 \times 10$	36.59	33.33	30.88	28.82	27.06
$L_1 + schedule L_2$	36.51	33.36	30.79	28.84	27.07
$schedule(L_1 + L_2)$	36.50	33.38	30.82	28.88	27.13

実装には PyTorch(バージョン 0.4.0)[25] を用い、最適化手法は Adam[26] を採用、学習率は 10^{-4} で他のパラメーターは PyTorch のデフォルトの値を使用した。バッチサイズは 32、学習回数は 320 epoch (416,000 iteration) とし、4.1 に示した 6 つの損失関数について実験を行なった。なお、評価する際に用いるモデルはテストデータにおけるの誤差が最も低くなったモデル (" $L_1 + schedule L_2$ " と " $schedule(L_1 + L_2)$ " については α_1, α_2 の値が固定される 250 epoch 以降のモデルの中で) を使用した。

4.2.2 評価方法

雑音除去の実験において画質を定量的に評価する指標として、PSNR[27] を用いた。また、評価画像には、図 2 に示す標準画像データベース SIDBA (Standard Image Database) の 12 種類の画像を用いた。なお、評価画像のサイズは全て 256×256 画素である。評価画像に 10%, 20%, 30%, 40%, 50% のランダム値雑音を加え、それぞれの損失関数で学習したモデルを用いて雑音除去を行い、それぞれの結果画像の PSNR を測定し、全評価画像の PSNR の平均値をそれぞれ計算する。

4.3 実験結果

表 1 に、それぞれの損失関数を用いた雑音除去の結果を示す。

表 1 より、 L_1 誤差、 L_2 誤差だけを用いるよりも、組み合わせるほうが、多少結果が良くなることが分かった。また、今回検討した損失関数の中では、" $L_1 + L_2 \times 10$ "

と” $schedule(L_1 + L_2)$ ”が他の損失関数に比べて良い結果になり、雑音付加率が低い時は” $L_1 + L_2 \times 10$ ”，雑音付加率が高い時には” $schedule(L_1 + L_2)$ ”が、僅かながら良くなる傾向があった。

5. Squeeze-and-Excitation block を用いる検討

本章では、我々のネットワークに Squeeze-and-Excitation block[28] を用いることで、精度が向上するかを調べた。

5.1 Squeeze-and-Excitation block と適用位置

Squeeze-and-Excitation block (SE block) は、チャンネル間の相互関係を明示的に取り入れて、畳み込み層のチャンネルに対して Attention を与えることができる。また、少ない計算量の増加で精度の向上が行えることで知られている。図 3 に SE block の構造を示す。なお、本章で用いた SE block の” r ”の値は 16 とした。

図 4 に、本章で検討した SE block の適用位置を示す。今回の実験では、図 4 に示した (α) , (β) , (γ) のそれぞれの位置のみに SE block を適用した場合と、いくつか組み合わせた場合で、下記の条件でそれぞれ実験を行なった。

- (α) の位置のみ
- (β) の位置のみ
- (γ) の位置のみ
- (α) と (β) の位置*1
- (α) と (γ) の位置

5.2 実験方法

使用したデータセットと学習条件は、4.2.1 と同様であり、損失関数は、4.1 で示した $schedule(L_1 + L_2)$ を用い

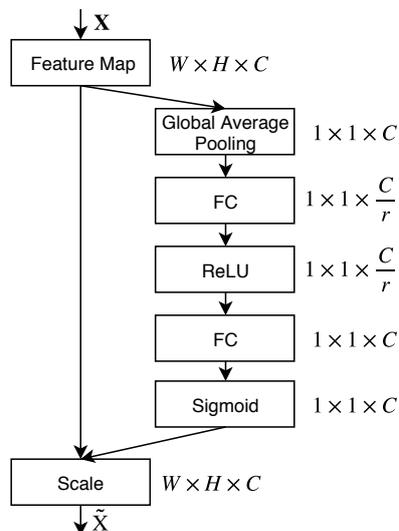


図 3: SE block の構造 [28]

*1 「 (α) と (β) 」の位置の実験では点線の矢印の方を使用。

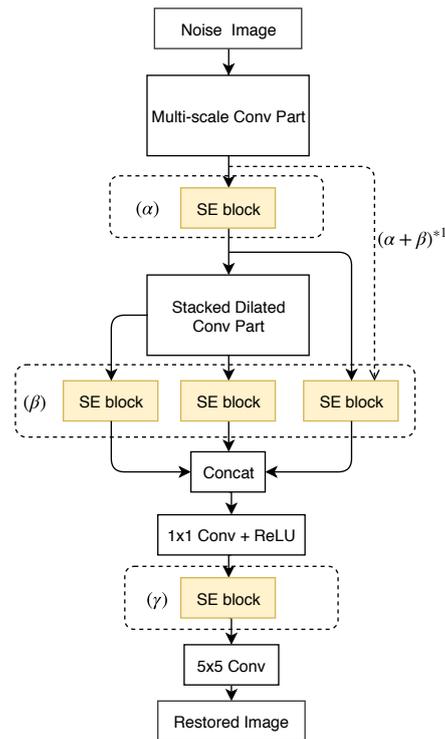


図 4: SE block の適用位置

表 2: それぞれの SE block 適用位置における平均 PSNR の比較

SE block の適用位置	雑音付加率				
	10%	20%	30%	40%	50%
なし	36.50	33.38	30.82	28.88	27.13
(α) のみ	36.67	33.44	30.92	28.94	27.09
(β) のみ	36.53	33.39	30.92	28.92	27.11
(γ) のみ	36.64	33.45	30.91	28.93	27.10
(α) と (β)	36.72	33.50	30.92	28.93	27.10
(α) と (γ)	36.75	33.48	30.99	28.98	27.14

た。 $schedule(L_1 + L_2)$ を用いた理由は 4 章の実験において、5 つの雑音付加率のうち 3 つの割合において一番良い結果となったからである。また、評価方法についても 4.2.2 と同様に行なった。

5.3 実験結果

表 2 に SE block をそれぞれの位置に用いた時および用いなかった時の雑音除去結果を示す。

表 2 より、特に雑音付加率が低い時において、SE block を用いた方が用いなかった時に比べて、平均 PSNR の値が大きくなるという結果になった。しかし、雑音付加率が高くなるにつれて平均 PSNR の値の差は小さくなり、特に雑音付加率が 50% でほとんど変わらないという結果になった。また、今回検討した SE block の適用位置の中では、 (α) と (γ) の位置に適用した結果が最も良くなった。

5.4 フィルタリング法との比較

本節では、インパルス性雑音におけるフィルタリング法

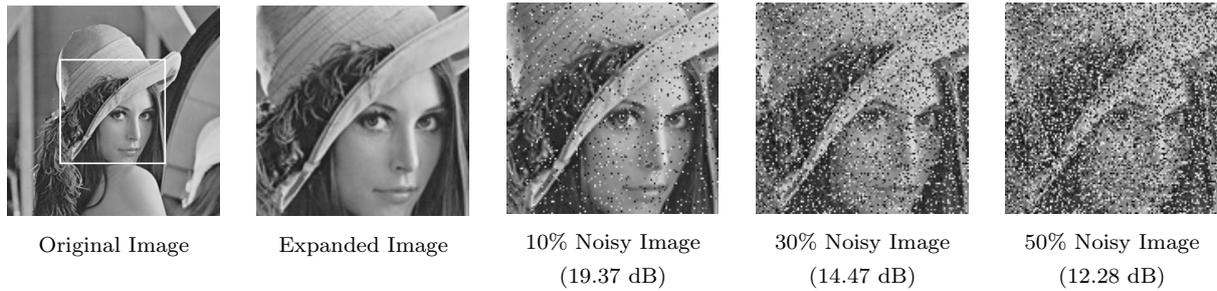
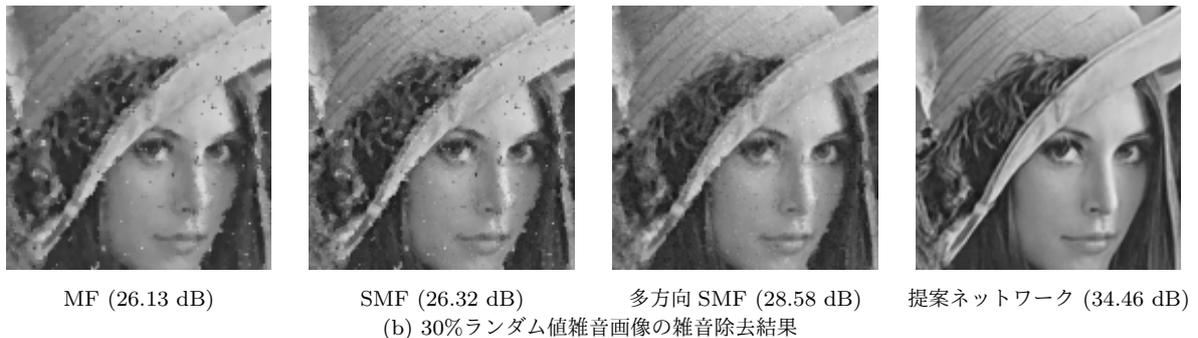


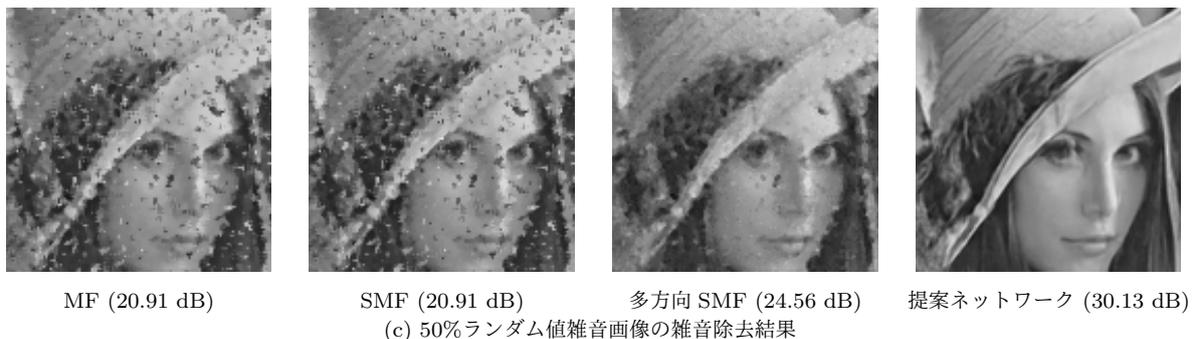
図 5: Lenna の原画像とランダム値雑音を加えた画像



(a) 10%ランダム値雑音画像の雑音除去結果



(b) 30%ランダム値雑音画像の雑音除去結果



(c) 50%ランダム値雑音画像の雑音除去結果

図 6: 各手法によるランダム値雑音画像の雑音除去結果

と提案したネットワークの雑音除去性能を比較する。フィルタリング法には、MF 法 [1], SMF 法 [2], 我々がすでに提案した多方向 SMF 法 [6] を用い、SMF 法と多方向 SMF 法はそれぞれの画像に対して最適なしきい値を用いた。また、我々のネットワークの結果には、SE block を (α) と (γ) の位置に適用した際のモデルを用いた。評価方法は、4.2.2 とほぼ同様に行なったが、フィルタリング法は画像周辺の処理は、内部と同じように処理が出来ないという問

題があるため、雑音を付加する際に周辺一画素には雑音を加えず、また、フィルタリング法で雑音除去する際は周辺一画素は未処理で行った。

表 3 に、フィルタリング法と我々のネットワークの雑音除去結果の比較を示す。

表 3 より、全ての雑音付加率において、我々の提案ネットワークがフィルタリング法と比べて、PSNR の平均値が約 5dB 程度大きくなり、精度面では、フィルタリング法よ

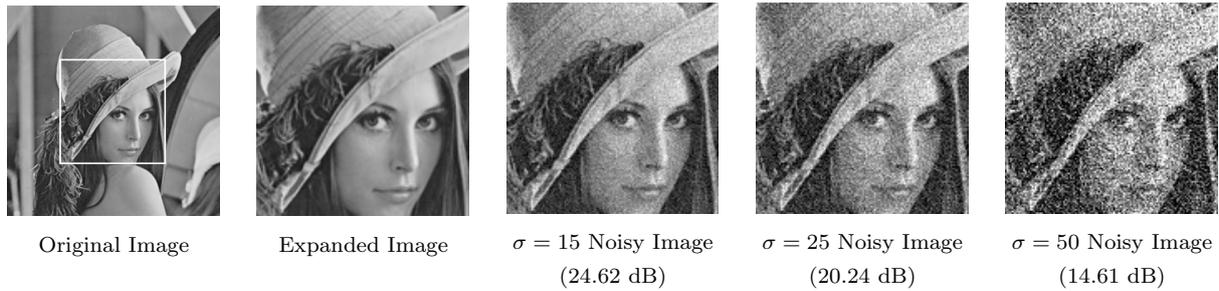


図 7: Lenna の原画像とガウス性雑音を加えた画像



(a) $\sigma = 15$ のガウス性雑音画像の除去結果



(b) $\sigma = 25$ のガウス性雑音画像の除去結果



(c) $\sigma = 50$ のガウス性雑音画像の除去結果

図 8: 各手法によるガウス性雑音画像の除去結果

表 3: フィルタリング法との比較結果

手法名	雑音付加率				
	10%	20%	30%	40%	50%
MF	27.16	25.65	23.70	21.48	19.24
SMF	28.99	26.36	23.94	21.54	19.24
多方向 SMF	30.63	28.06	26.22	24.47	22.60
提案ネットワーク	36.68	33.44	31.14	29.16	27.25

り有効であることが確認できた。図 5 に、図 2 の Lenna の画像について、原画像と、10%、30%、50%の割合でランダム値雑音を与えた画像を示す。また、図 6 に、各手法で雑音除去した結果画像を示す。

6. ガウス性雑音除去

本章では、提案したネットワークがガウス性雑音に対してどれほど有効かを調べ、結果を報告する。

表 4: 各手法によるガウス性雑音除去結果

手法名	雑音付加率			
	$\sigma = 15$	$\sigma = 25$	$\sigma = 35$	$\sigma = 50$
BM3D	30.90	28.25	26.54	24.74
WNNM	31.19	28.44	26.51	24.64
TNRD	31.03	28.36	-	24.73
提案ネットワーク	31.33	28.72	27.15	25.62

6.1 実験方法

6.1.1 使用したデータセットとネットワーク学習

使用したネットワークの構造は、図1のネットワークに図4の (α) と (γ) の位置にSE blockを用いたものである。使用したデータセットは、4.2.1で収集し、4分割した画像(128×128画素)に対して、 $\sigma = 15, 25, 35, 50$ の割合でガウス性雑音を加え、雑音画像と原画像のペアを訓練データとして41,600個(一雑音付加率あたりのペア数は10,400個)、テストデータとして10,400個(一雑音付加率あたりのペア数は2,600個)作成したものをを用いた。損失関数は4.1で示した $schedule(L_1 + L_2)$ を用い、その他の条件は4.2.1と同様とした。

6.1.2 評価方法

評価は $\sigma = 15, 25, 35, 50$ の割合でガウス性雑音を加えた図2の評価画像に対して、4.2.2と同様な方法で行なった。また、比較手法として、ガウス性雑音除去の研究において、よく比較に用いられているBM3D[12]*2, WNNM[13]*3, TNRD[14]*4の3手法を用いた。

6.2 実験結果

表4に、ガウス性雑音に対する提案ネットワークと比較手法の雑音除去結果を示す。

表4より、全ての σ の値において提案したネットワークの結果は比較に用いた手法と比べて、PSNRの平均値が高くなった。また、 σ の値が小さい時の提案ネットワークと比較手法の平均PSNRの値の差は僅かであるが、 σ の値が大きくなるにつれて、差が大きくなる傾向がある。図7に図2のLennaの画像について、原画像と、 $\sigma = 15, 25, 50$ の値としたガウス性雑音を与えた画像を示す。また、図8に各手法で雑音除去した結果を示す。

7. まとめ

本稿では、インパルス性雑音除去のためのネットワークを提案し、損失関数に関する検討、SE blockを用いる検討を行なった。結果として、損失関数は L_1 誤差、 L_2 誤差だけを用いる時よりも、組み合わせたほうが多少結果が良く

なることが分かり、SE blockを用いる事で僅かに結果が良くなった。また、ガウス性雑音に対してもある程度有効であることが分かった。

今後の展望として、我々のネットワークが、カラー画像に対しても有効かの確認、2章で述べたような他の深層学習を用いた手法との比較を行うことが挙げられる。また、本稿では、人工的に雑音を与えた画像のみで評価を行ったが、実際の雑音を含む画像を用いて評価を行っていきたい。

謝辞 本研究の一部は独立行政法人日本学術振興会の科学研究費(基盤研究(C):課題番号16K00260)の助成を得て行われた。

参考文献

- [1] P.M. Narendra: *A separable median filter for image noise smoothing*, IEEE Trans. Pattern Anal. Mach. Intell., vol.PAMI-3, no.1, pp.20-29 (1981).
- [2] Tong Sun, Y. Neuvo: *Detail-preserving median based filters in image processing*, Pattern Recognition Letters, vol.15, no.4, pp.341-347 (1994).
- [3] Zhou Wang, D.Zhang: *Progressive switching median filter for the removal of impulse noise from highly corrupted images*, IEEE Trans. Circuits Syst. II, vol.46, no.1, pp.78-80 (1999).
- [4] Shuqun Zhang, M.A. Karim: *A new impulse detector for switching median filters*, IEEE Signal Process. Lett., vol.9, no.11, pp.360-363 (2002).
- [5] Yiqiu Dong, Raymond H. Chan, Shufang Xu: *A Detection Statistic for Random-Valued Impulse Noise* IEEE Trans. Image Process., vol.16, no.6, pp.1112-1120 (2007).
- [6] 横山靖樹, 宮崎 敬, 曾根光男, 山本博章: 多方向走査平均処理と 2×2 雑音検出器を組み合わせたスイッチングメジアンフィルタ, 信学会(A), vol.J95-A, no.10, pp.737-750 (2012).
- [7] 横山靖樹, 宮崎 敬, 曾根光男, 山本博章: 多方向スイッチングメジアンフィルタのための画像分割とエッジ情報によるしきい値設定, 画像電子学会誌, vol.44, No.3 (2015).
- [8] 木村誠聡, 大谷紀子, 田口 亮: 多数決機械を用いたインパルス性雑音の検出法, 信学会(A), vol.J91-A, no.9, pp.929-933 (2008).
- [9] J. Portilla, V. Strela, M.J. Wainwright, E.P. Simoncelli: *Image denoising using scale mixtures of Gaussians in the wavelet domain*, IEEE Transactions on Image Processing, vol.12, no.11, pp.1338-1351 (2003).
- [10] Michael Elad, Michal Aharon: *Image Denoising Via Sparse and Redundant Representations Over Learned Dictionaries*, IEEE Transactions on Image Processing, vol.15, no.12, pp.3736-3745 (2006).
- [11] Viren Jain and H. Sebastian Seung: *Natural Image Denoising with Convolutional Networks*, In. Neural Information Processing Systems (NIPS), (2008).
- [12] Kostadin Dabov, Alessandro Foi, Vladimir Katkovnik, Karen Egiazarian: *Image Denoising by Sparse 3-D Transform-Domain Collaborative Filtering*, IEEE Trans. Image Process., vol.16, no.8, pp.2080-2095 (2007).
- [13] S. Gu, L. Zhang, W. Zuo, and X. Feng: *Weighted Nuclear Norm Minimization with Application to Image Denoising*, In. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.2862-2869, (2014).
- [14] Yunjin Chen, Thomas Pock: *Trainable Nonlinear Re-*

*2 <https://github.com/gfaccio1/bm3d> のコードを使用

*3 http://www4.comp.polyu.edu.hk/~cslzhang/code/WNNM_code.zip のコードを使用

*4 <https://www.dropbox.com/s/8j6b880m6ddxtee/TNRD-Codes.zip?dl=0> のコードを使用

- action Diffusion: A Flexible Framework for Fast and Effective Image Restoration* IEEE Trans Pattern Anal Mach Intell., vol.39, no.6, pp.1256-1272 (2017).
- [15] Kai Zhang, Wangmeng Zuo, Yunjin Chen, Deyu Meng, Lei Zhang: *Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising*, IEEE Transactions on Image Processing, vol.26, no.7, pp.3142-3155 (2017).
- [16] Xiao-Jiao Mao, Chunhua Shen, Yu-Bin Yang: *Image restoration using very deep convolutional encoder-decoder networks with symmetric skip connections*, In. Neural Information Processing Systems (NIPS), pp.2810-2818 (2016).
- [17] Kai Zhang, Wangmeng Zuo, Lei Zhang: *FFDNet: Toward a Fast and Flexible Solution for CNN-Based Image Denoising*, IEEE Transactions on Image Processing, vo.27, no.9, pp.4608-4622 (2018).
- [18] Ben Mildenhall, Jonathan T. Barron, Jiawen Chen, Dillon Sharlet, Ren Ng, Robert Carroll: *Burst Denoising with Kernel Prediction Networks*, In. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 2502-2510 (2018).
- [19] Jingwen Chen, Jiawei Chen, Hongyang Chao, Ming Yang: *Image Blind Denoising With Generative Adversarial Network Based Noise Modeling*, In. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.3155-3164 (2018).
- [20] Jaakko Lehtinen, Jacob Munkberg, Jon Hasselgren, Samuli Laine, Tero Karras, Miika Aittala, Timo Aila: *Noise2Noise: Learning Image Restoration without Clean Data*, In. International Conference on Machine Learning (ICML), pp.2965-2974 (2018).
- [21] Ryosuke Kubota, Noriaki Suetake: *Distribution distance-based threshold auto-tuning method for switching median filter*, IEICE Electronics Express, vol.7, no.17, pp.1310-1316 (2010).
- [22] Fisher Yu and Vladlen Koltun: *Multi-scale context aggregation by dilated convolutions*, In. International Conference on Learning Representations (ICLR), (2016).
- [23] Nair, V., Hinton, G.E.: *Rectified linear units improve restricted boltzmann machines*, In. International Conference on Machine Learning (ICML), pp.807-814 (2010).
- [24] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich: *Going deeper with convolutions*, In. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.1-9 (2015).
- [25] Paszke, Adam and Gross, Sam and Chintala, Soumith and Chanan, Gregory and Yang, Edward and DeVito, Zachary and Lin, Zeming and Desmaison, Alban and Antiga, Luca and Lerer, Adam: *Automatic differentiation in PyTorch*, In. Neural Information Processing Systems (NIPS), (2017).
- [26] D.P. Kingma, L.J. Ba: *Adam: A Method for Stochastic Optimization*, In. International Conference on Learning Representations (ICLR), (2015).
- [27] Q. Huynh-Thu and M. Ghanbari: *Scope of validity of PSNR in image/video quality assessment*, Electronics Letters, Vol. 44, No. 13, p800-801 (2008).
- [28] Jie Hu, Li Shen, Gang Sun: *Squeeze-and-Excitation Networks*, In. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.7132-7141 (2018).