

不確実性を考慮した Retinex 理論に基づく低照度画像強調 Uncertainty-Aware Retinex Low-Light Image Enhancement

○竹山 慎吾, 萩原 義裕, 佐々木 誠, 堀田 克哉

○ Shingo Takeyama, Yoshihiro Hagihara, Makoto Sasaki, Katsuya Hotta,

岩手大学,

Iwate University,

キーワード : 画像強調 (image enhancement), Retinex 理論 (retinex theory)

連絡先 : 〒 020-8551 岩手県盛岡市上田 4-3-5 岩手大学 萩原研究室
萩原義裕, Tel.: 019-621-6400, E-mail: dhag@iwate-u.ac.jp

1. はじめに

近年, 低照度画像強調 (Low-Light Image Enhancement; LLIE) ¹⁾ では, 人間の視覚恒常性に基づく Retinex 理論 ^{2, 3)} を深層学習に統合する研究が広く注目されている. Retinex 理論は, 観測画像を反射率成分と照明成分の相互作用としてモデル化することで, 低照度劣化を照明変動に起因する物理的に解釈可能な問題として扱うことを可能にする. この性質に基づき, 近年の学習型 LLIE 手法では, Retinex 分解を深層ネットワークに組み込み, 反射率および照明成分を明示的に推定しながら高品質な復元画像を生成する枠組みが提案されている ^{4, 5, 6)}.

しかし, 実際の低照度画像において, 復元の困難性は空間的に一様ではない. 軽度の露光不足を含む平坦領域では, 照明成分の補正のみで十分な場合がある. 一方で, 強いノイズ, 飽和, 複雑なテクスチャ, または非一様照明を含む領域では, Retinex 分解に基づく初期復元だけでは十分な画質改善が得られない場合がある ⁷⁾. このような領域依存の劣化を無視して一様な補

正を適用すると, 信頼性の高い領域では過強調が生じ, 復元が困難な領域では補正不足が残る ⁸⁾. したがって, Retinex 分解が持つ解釈性を保持しつつ, 復元信頼性の低い領域に対してのみ補正を適応的に強化する枠組みが重要となる.

本研究では, Retinex 分解の解釈性と深層ネットワークの高い復元能力を統合するために, 不確実性を考慮した Retinex 理論に基づく LLIE フレームワークを提案する. 具体的には, 入力低照度画像から反射率, 照明, 劣化成分, および不確実性マップを同時に推定し, 照明補正に基づいて物理的に解釈可能な初期強調画像を生成する. さらに, 推定された不確実性マップを空間的なゲーティング信号として用いることで, 局所的な残差補正の強度を画素ごとに適応的に制御する. この設計により, 信頼性の高い領域では Retinex 初期復元を保持し, 復元が困難な領域ではデータ駆動型の補正を選択的に強化できる. その結果, 提案手法は, 過強調を抑制しつつ, ノイズ, 非一様照明, および局所的な露光不足に対して柔軟な復元を実現する. 評価実験

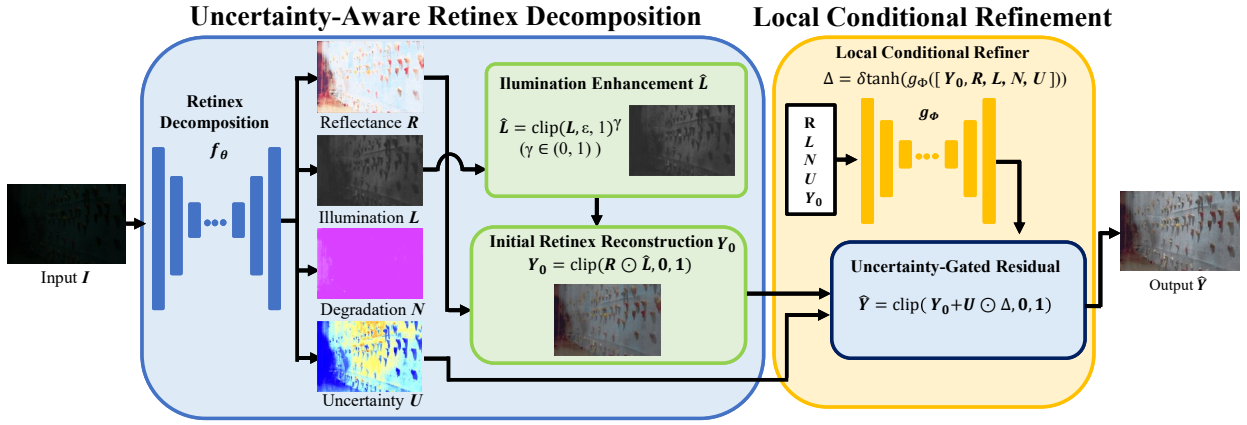


Fig. 1 提案手法の概要.

では、低照度画像データセットを用いた評価により、提案手法の不確実性を考慮した Retinex 理論の有効性を示す。

本研究の主な貢献は次の2点である:(1) Retinex 分解と不確実性に基づく局所的残差補正を統合した解釈可能かつ適応的な LLIE フレームワークを提案する。(2) 入力低照度画像を反射率、照明、劣化成分、および不確実性マップに分解し、不確実性マップを空間的な制御信号として用いることで、領域ごとの補正強度を適応的に調整する分解・補正アーキテクチャを設計する。

2. 提案手法

既存の Retinex ベースの低照度画像強調手法は、反射率と照明を明示的に分解することで解釈可能な復元を実現できる。しかし、実際の低照度画像では、劣化の程度が空間的に大きく異なるため、分解後の補正を画像全体に一律に適用すると、信頼性の高い領域では過強調が生じ、復元が困難な領域では補正不足が残る可能性がある。

この問題に対処するため、本研究では、図1に示すように、不確実性を考慮した Retinex 理論に基づく低照度画像強調フレームワークを提案する。提案手法の基本的な考え方は、Retinex 分解によって物理的に解釈可能な初期強調画像を生成し、その復元信頼性を不確実性マップと

して推定することで、追加補正が必要な領域を明示的に制御することである。具体的には、入力低照度画像を反射率、照明、劣化成分、および不確実性マップに分解し、照明補正に基づいて初期強調画像を生成する。その後、不確実性マップを空間的なゲーティング信号として用いることで、局所的な残差補正の寄与を画素ごとに調整する。これにより、信頼性の高い領域では Retinex に基づく初期復元を保持し、復元が困難な領域ではデータ駆動型の補正を選択的に強化することができる。

2.1 問題設定

低照度 RGB 画像を $I \in [0, 1]^{3 \times H \times W}$, 対応する通常照明画像を $Y \in [0, 1]^{3 \times H \times W}$ とする。低照度画像強調の目的は、入力画像 I から、通常照明画像 Y に近い強調画像 \hat{Y} を推定することである。本研究では、入力画像から出力画像を直接推定するブラックボックスな写像ではなく、Retinex 理論^{2, 3)}に基づく分解構造を用いて画像復元過程を定式化する。

具体的には、入力画像 I を反射率 $R \in [0, 1]^{3 \times H \times W}$, 照明 $L \in [0, 1]^{1 \times H \times W}$, および劣化成分 $N \in [-\eta, \eta]^{3 \times H \times W}$ により、次式のように近似する。

$$I \simeq R \odot L + N, \quad (1)$$

ここで、 \odot は要素ごとの積を表し、照明成分 L は RGB 各チャンネルにブロードキャストされる。

N は、低照度画像に含まれるノイズや Retinex 分解では説明しきれない残差的な劣化を表す。さらに、本研究では不確実性マップ $U \in [0, 1]^{1 \times H \times W}$ を導入する。 U は、Retinex 分解に基づく初期復元の信頼性が低く、追加の局所補正が必要な領域を表す空間的な制御信号として用いる。

2.2 不確実性を考慮した Retinex 分解

提案手法は、Retinex 分解ネットワーク f_θ と局所補正ネットワーク g_ϕ から構成される。まず、Retinex 分解ネットワークは、入力低照度画像 I から反射率 R 、照明 L 、劣化成分 N 、および不確実性マップ U を同時に推定する。

$$\{R, L, N, U\} = f_\theta(I). \quad (2)$$

ここで、反射率 R 、照明 L 、および不確実性 U は、シグモイド関数により $[0, 1]$ の範囲に制約する。一方、劣化成分 N は小さな残差成分として扱うため、スケール付き双曲線正接関数により $[-\eta, \eta]$ の範囲に制約する。

次に、推定された照明成分 L に対してガンマ補正を適用し、補正後の照明 \hat{L} を得る。

$$\hat{L} = \text{clip}(L, \epsilon, 1)^\gamma, \quad (3)$$

ここで、 $\epsilon = 10^{-4}$ は安定性のため下限値であり、 γ は照明補正の強度を制御するパラメータである。本研究では、 $\gamma < 1$ とすることで暗い照明値を明るく補正する。補正後の照明 \hat{L} を用いて、Retinex モデルに基づく初期強調画像 Y_0 を生成する。

$$Y_0 = \text{clip}(R \odot \hat{L}, 0, 1). \quad (4)$$

2.3 不確実性に基づく局所的残差補正

Retinex 分解によって得られる初期強調画像 Y_0 は、Retinex モデルに基づく解釈可能な復元結果である。しかし、強いノイズ、非一様照明、飽和、複雑なテクスチャ、または局所的な露光

不足を含む領域では、Retinex 分解のみでは十分な復元品質を得られない場合がある。そこで、本研究では、不確実性マップ U を用いて初期復元の信頼性が低い領域を明示的に推定し、その領域に対してのみ残差補正を強く反映させる。

不確実性マップ U は、Retinex 分解による入力画像の説明誤差に基づいて学習される。具体的には、画素位置 p におけるチャンネル平均 Retinex 残差を定義する。

$$e_{\text{ret}}(p) = \frac{1}{3} \sum_c |I_c(p) - R_c(p)L(p) - N_c(p)|. \quad (5)$$

この残差は、推定された反射率、照明、および劣化成分が入力画像をどの程度説明できているかを表す。すなわち、 $e_{\text{ret}}(p)$ が大きい画素では、Retinex 分解に基づく初期復元の信頼性が低いとみなせる。ただし、残差の絶対スケールは画像ごとに異なるため、各画像内で正規化した残差を次式で求める。

$$\tilde{e}_{\text{ret}}(p) = \frac{e_{\text{ret}}(p)}{\max_q e_{\text{ret}}(q) + \epsilon_u}, \quad \epsilon_u = 10^{-6}. \quad (6)$$

本研究では、この正規化残差 \tilde{e}_{ret} を自己教師的な不確実性ターゲットとして用いることで、 U が Retinex 分解では表現しにくい領域を表すように促す。

次に、局所補正ネットワーク g_ϕ を用いて、初期強調画像 Y_0 に対する残差補正 Δ を推定する。局所補正ネットワークは、初期強調画像 Y_0 、反射率 R 、照明 L 、不確実性マップ U 、および劣化成分 N を入力とし、有界な残差補正を出力する。

$$\Delta = \delta \tanh(g_\phi([Y_0, R, L, U, N])), \quad (7)$$

ここで、 $[\cdot]$ はチャンネル方向の結合を表し、 δ は残差補正の最大振幅を制御する定数である。本研究では、 $\delta = 0.2$ とする。最終的な強調画像 \hat{Y} は、不確実性マップ U によって残差補正 Δ の寄与を画素ごとに制御することで得られる。

$$\hat{Y} = \text{clip}(Y_0 + U \odot \Delta, 0, 1). \quad (8)$$

これより、 U が小さい領域では、モデルは Retinex に基づく初期強調画像 Y_0 を主に信頼する。一方で、 U が大きい領域では、残差補正 Δ の寄与が強くなり、復元が困難な領域に対してより積極的な補正が行われる。したがって、提案手法における不確実性マップは、単なる中間特徴ではなく、最終的な強調画像を形成するための明示的な空間ゲーティング信号として機能する。

2.4 学習目的

提案手法は、通常照明画像への復元精度を高めると同時に、Retinex 分解の整合性、不確実性推定の妥当性、および強調画像の自然性を保つように学習される。全体の損失関数は次式で定義される。

$$\mathcal{L} = \lambda_{\text{rec}} \mathcal{L}_{\text{rec}} + \lambda_{\text{ret}} \mathcal{L}_{\text{ret}} + \lambda_{\text{unc}} \mathcal{L}_{\text{unc}} + \lambda_{\text{ref}} \mathcal{L}_{\text{ref}} + \mathcal{L}_{\text{reg}}. \quad (9)$$

ここで、 \mathcal{L}_{rec} は教師画像に対する再構成損失、 \mathcal{L}_{ret} は Retinex 分解の整合性損失、 \mathcal{L}_{unc} は不確実性整合性損失、 \mathcal{L}_{ref} は不確実性に基づく局所補正損失である。また、 \mathcal{L}_{reg} は照明平滑性、露光補正、色恒常性、および全変動正則化を含む補助的な正則化項である。

再構成損失 \mathcal{L}_{rec} は、出力画像 \hat{Y} と教師画像 Y の差を最小化する。

$$\mathcal{L}_{\text{rec}} = \|\hat{Y} - Y\|_1. \quad (10)$$

Retinex 整合性損失は、推定された反射率、照明、および劣化成分が入力画像を説明できるように制約する。

$$\mathcal{L}_{\text{ret}} = \|R \odot L + N - I\|_1. \quad (11)$$

不確実性整合性損失 \mathcal{L}_{unc} は、推定不確実性 U と正規化 Retinex 残差 \tilde{e}_{ret} の整合性を促す。

$$\mathcal{L}_{\text{unc}} = \frac{1}{HW} \sum_p |U(p) - \text{sg}(\tilde{e}_{\text{ret}}(p))|, \quad (12)$$

ここで、 $\text{sg}(\cdot)$ は stop-gradient 演算を表す。これにより、正規化 Retinex 残差 \tilde{e}_{ret} を不確実性

マップ U の疑似教師信号として固定し、 \mathcal{L}_{unc} が R , L , N を直接更新することを防ぐ。その結果、 U は Retinex 分解による再構成が困難な領域を高い不確実性として表現するように学習される。

さらに、不確実性の高い領域における復元誤差を重点的に最小化するため、局所補正損失 \mathcal{L}_{ref} を導入する。

$$\mathcal{L}_{\text{ref}} = \frac{1}{HW} \sum_p \text{sg}(U(p)) \left\| \hat{Y}(p) - Y(p) \right\|_1. \quad (13)$$

ここでは、 U 自身がこの損失を小さくする方向へ自明に変化することを避けるため、重みとして用いる不確実性には stop-gradient を適用する。

補助正則化項 \mathcal{L}_{reg} は、次式でまとめて表す。

$$\mathcal{L}_{\text{reg}} = \lambda_{\text{illum}} \mathcal{L}_{\text{illum}} + \lambda_{\text{exp}} \mathcal{L}_{\text{exp}} + \lambda_{\text{color}} \mathcal{L}_{\text{color}} + \lambda_{\text{tv}} \mathcal{L}_{\text{tv}}. \quad (14)$$

$\mathcal{L}_{\text{illum}}$ は照明成分の不要な高周波変動を抑制し、 \mathcal{L}_{exp} は出力画像の明るさを適切な範囲に誘導する。 $\mathcal{L}_{\text{color}}$ は RGB チャネル間の不自然な色ずれを抑制し、 \mathcal{L}_{tv} は局所的な過度な変動を抑えるために用いる。

2.5 推論

推論時には、入力低照度画像 I に対して、反射率 R 、照明 L 、劣化成分 N 、不確実性マップ U 、初期強調画像 Y_0 、および最終的な強調画像 \hat{Y} を得る。具体的には、まず Retinex 分解ネットワーク f_θ により $\{R, L, N, U\}$ を推定し、照明補正後の \hat{L} を用いて初期強調画像 Y_0 を生成する。その後、局所補正ネットワーク g_ϕ により残差補正 Δ を推定し、不確実性マップ U を用いてその寄与を画素ごとに制御することで、最終的な強調画像 \hat{Y} を出力する。

3. 評価実験

ベンチマーク。本研究では、LOL-v1⁹⁾、LOL-v2-real および LOL-v2-synthetic¹⁰⁾ で評価する。

Table 1 LOL (v1⁹⁾ および v2¹⁰⁾) における定量的評価 (PSNR, SSIM).

	LOL-v1 ⁹⁾		LOL-v2-real ¹⁰⁾		LOL-v2-synthetic ¹⁰⁾	
	PSNR ↑	SSIM ↑	PSNR ↑	SSIM ↑	PSNR ↑	SSIM ↑
RetinexNet ⁹⁾	16.77	0.560	15.47	0.567	<u>17.13</u>	<u>0.798</u>
KinD ⁴⁾	<u>20.86</u>	<u>0.790</u>	14.74	0.641	13.29	0.578
RUAS ⁵⁾	18.23	0.720	<u>18.37</u>	<u>0.723</u>	16.55	0.652
Ours	21.61	0.852	21.25	0.839	23.64	0.912

LOL-v1 は、実低照度画像と対応する通常照明画像のペアから構成される代表的な低照度画像強調データセットである。LOL-v2 は、より多様な低照度条件を含む拡張データセットであり、実画像から構成される LOL-v2-real と、合成低照度画像から構成される LOL-v2-synthetic を含む。

評価指標. 定量評価には、Peak Signal-to-Noise Ratio (PSNR) および Structural Similarity Index Measure (SSIM) を用いる。PSNR は教師画像に対する画素値レベルの復元精度を評価し、SSIM は構造的な類似性を評価する。いずれの指標も、値が高いほど良好な復元性能を示す。

3.1 ベンチマーク結果

Table 1 に、LOL-v1, LOL-v2-real, および LOL-v2-synthetic における定量的評価結果を示す。比較手法として、RetinexNet⁹⁾, KinD⁴⁾, および RUAS⁵⁾ を用いる。

Table 1 から、提案手法はすべてのデータセットにおいて最も高い PSNR および SSIM を達成することを確認できる。特に、LOL-v1 および LOL-v2-real における精度向上は、実低照度画像に含まれるノイズや非一様照明に対して、提案手法の不確実性マップが有効に機能することを示している。さらに、LOL-v2-synthetic において、提案手法の PSNR は比較手法に比べて 6.51dB の改善が得られており、合成的な低照度劣化に対しても高い復元性能を示すことが確認できる。以上の結果から、Retinex 分解に基づ

Table 2 LOL-v2-real¹⁰⁾ における提案手法のアブレーション研究。

Setting	PSNR ↑
w/o uncertainty map	20.87
w/ uncertainty map	21.25

く初期復元と不確実性に基づく局所的な残差補正を組み合わせることの有効性が確認できる。

3.2 不確実性マップの有効性

不確実性マップの寄与を検証するため、LOL-v2-real¹⁰⁾ においてアブレーション実験を行った。表 2 に不確実性マップの有無による PSNR, 図 2 に視覚的な結果を示す。

表 2 から、不確実性マップを用いない場合、PSNR は 20.87 であった。一方、不確実性マップを導入した場合、PSNR は 21.25 に向上した。この結果は、不確実性マップによって局所的な残差補正の寄与を制御することが、低照度画像強調の性能向上に寄与することを示している。特に、Retinex 分解のみでは復元が困難な領域に対する適応的な画像強調が有効であると考えられる。図 2 においても、不確実性マップを導入した提案手法はより細かな輪郭を補正できていることが確認できる。したがって、提案手法における不確実性マップは、局所的な補正強度を制御するための有効な空間的ゲーティング信号として機能することが確認できる。

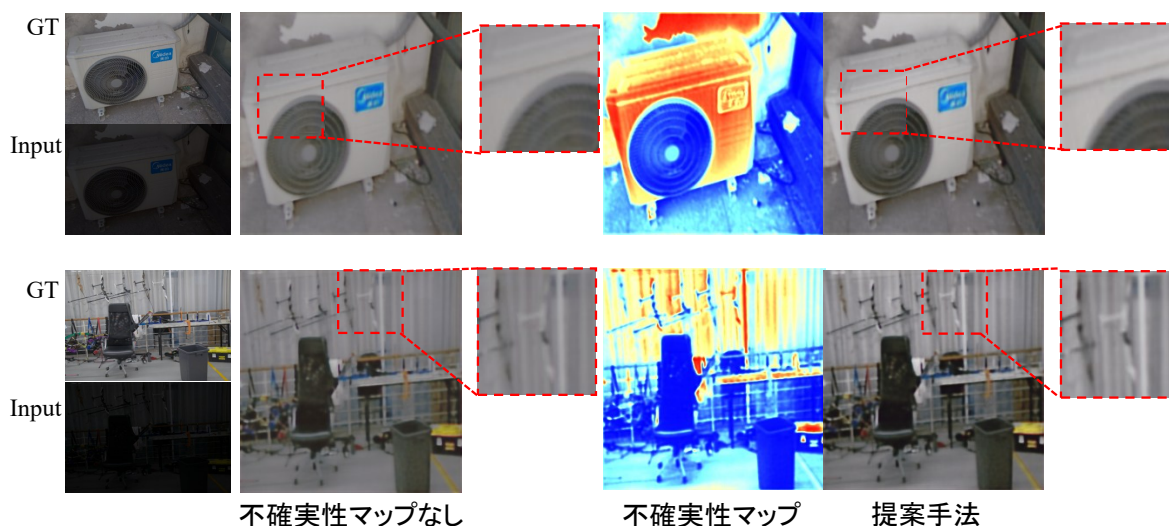


Fig. 2 提案手法における視覚的な結果.

4. まとめ

本研究では、低照度画像における空間的に不均一な劣化に着目し、不確実性を考慮した Retinex 理論に基づく低照度画像強調手法を提案した。これにより、信頼性の高い領域では過度な補正を抑制しつつ、ノイズや非一様照明を含む領域では補正を強化することを可能にした。評価実験では、低照度画像データセットを用いた評価により、提案手法の不確実性を考慮した Retinex 理論の有効性を示した。

今後の課題としては、色再現性のさらなる向上や、強いノイズ、飽和、圧縮劣化を含むより低品質な画像への対応を行う予定である。

謝辞

本研究は JSPS 科研費 26K01849 および、岩手大学ソフトパス理工学総合研究センターの支援の助成を受けたものです。

参考文献

1) Y. Cai, H. Bian, J. Lin, H. Wang, R. Timofte, and Y. Zhang, “Retinexformer: One-stage retinex-based transformer for low-light image enhancement,” Proceedings

of the IEEE/CVF international conference on computer vision, pp.12504–12513, 2023.

- 2) E.H. Land and J.J. McCann, “Lightness and retinex theory,” Journal of the Optical society of America, vol.61, no.1, pp.1–11, 1971.
- 3) D.J. Jobson, Z.u. Rahman, and G.A. Woodell, “A multiscale retinex for bridging the gap between color images and the human observation of scenes,” IEEE Transactions on Image Processing, vol.6, no.7, pp.965–976, 1997.
- 4) Y. Zhang, J. Zhang, and X. Guo, “Kindling the darkness: A practical low-light image enhancer,” Proceedings of the 27th ACM International Conference on Multimedia, pp.1632–1640, 2019.
- 5) R. Liu, L. Ma, J. Zhang, X. Fan, and Z. Luo, “Retinex-inspired unrolling with cooperative prior architecture search for low-light image enhancement,” Proceedings of the IEEE/CVF Conference on

Computer Vision and Pattern Recognition, pp.10561–10570, 2021.

- 6) T. Wang, K. Zhang, T. Shen, W. Luo, B. Stenger, and T. Lu, “Ultra-high-definition low-light image enhancement: A benchmark and transformer-based method,” Proceedings of the AAAI Conference on Artificial Intelligence, pp.2654–2662, 2023.
- 7) C. Guo, C. Li, J. Guo, C.C. Loy, J. Hou, S. Kwong, and R. Cong, “Zero-reference deep curve estimation for low-light image enhancement,” Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp.1780–1789, 2020.
- 8) X. Xu, R. Wang, C.W. Fu, and J. Jia, “Snr-aware low-light image enhancement,” Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp.17714–17724, 2022.
- 9) W.Y.J.L. Chen Wei, Wenjing Wang, “Deep retinex decomposition for low-light enhancement,” British Machine Vision Conference, 2018.
- 10) W. Yang, W. Wang, H. Huang, S. Wang, and J. Liu, “Sparse gradient regularized deep retinex network for robust low-light image enhancement,” IEEE Transactions on Image Processing, vol.30, pp.2072–2086, 2021.