


Függelék

F.1. Adathalmaz



F.1.1. ábra. Variációk zavaró tényezőkből.

DEFAULT_IMAGE_ID	ARTIFACT_IMAGE_ID	has_hair	has_ruler	has_border	has_vignette	has_tint_marks
ISIC_9744723	ISIC_9744723_3	1	1	0	0	0
ISIC_9968564	ISIC_9968564_98	0	1	1	0	1
ISIC_4229473	ISIC_4229473_48	0	0	0	0	1


F.1. táblázat. Minták tényezők jelenlétét tartalmazó adattaláblából

F.2. A GAN tanítása

1. Algorithm GAN Tanítás


Require: $N_{\text{epochs}}, N_{\text{batches}}, \mathcal{X}^{\text{artifact}}, \mathcal{X}^{\text{clean}}$
Require: $\eta_D, \eta_G, \beta_1, \beta_2, \epsilon$
Require: $\lambda_{\text{TV}}, \delta, \lambda_{\text{adv}}, \lambda_{\text{L1}}, \lambda_{\text{perc}}$

- 1: **for** $epoch = 1$ to N_{epochs} **do**
- 2: **for** $i = 1$ to N_{batches} **do**
- 3: **Sample:** $\mathbf{x}_i \in \mathcal{X}^{\text{artifact}}, \mathbf{x}'_i \in \mathcal{X}^{\text{clean}}$
- 4: $\hat{\mathbf{x}}_i = g(\mathbf{x}_i, \theta_g^{i-1})$ ▷ Generate fake images
- 5: // Compute discriminator loss:
- 6: $\mathcal{L}_d(\hat{x}_i, x_i) = \mathbb{E}_{\hat{x}_i} [d(\hat{x}_i, \theta_d^{i-1})] - \mathbb{E}_{x_i} [d(x_i, \theta_d^{i-1})]$ ▷ Compute Wasserstein loss
- 7: $\mathcal{L}_d(\hat{x}_i, x_i) += \lambda_{\text{TV}} \cdot \mathbb{E}_{\mathbf{x}, \hat{\mathbf{x}}} [|d(\mathbf{x}_i, \theta_d^{i-1}) - d(g(\hat{\mathbf{x}}_i, \theta_g^{i-1}), \theta_d^{i-1}) - \delta|]$ ▷ Add R_{TV}
- 8: $m_i^d \leftarrow \beta_1 m_{i-1}^d + (1 - \beta_1) \nabla_d \mathcal{L}_d$
- 9: $v_i^d \leftarrow \beta_2 v_{i-1}^d + (1 - \beta_2) (\nabla_d \mathcal{L}_d)^2$
- 10: $\hat{m}_i^d \leftarrow \frac{m_i^d}{1 - \beta_1^i}$
- 11: $\hat{v}_i^d \leftarrow \frac{v_i^d}{1 - \beta_2^i}$
- 12: $\theta_d^i \leftarrow \theta_d^{i-1} - \eta_d \frac{\hat{m}_i^d}{\sqrt{\hat{v}_i^d} + \epsilon}$ ▷ Update discriminator d using Adam optimizer
- 13: // Update generator g :
- 14: $\mathcal{L}_{\text{L1}} = \|\mathbf{x}_i - \hat{\mathbf{x}}_i\|_1$ ▷ Compute L1 loss
- 15: $\mathcal{L}_{\text{adv}} = -\mathbb{E}_{\hat{x}_i} [d(\hat{x}_i, \theta_d^i)]$ ▷ Compute Wasserstein loss
- 16: $\mathcal{L}_{\text{perc}} = \|\Phi(\hat{\mathbf{x}}_i) - \Phi(\mathbf{x}_i)\|_1$ ▷ Compute perceptual loss
- 17: $\mathcal{L}_g = \lambda_{\text{L1}} \cdot \mathcal{L}_{\text{L1}} + \lambda_{\text{adv}} \cdot \mathcal{L}_{\text{adv}} + \lambda_{\text{perc}} \cdot \mathcal{L}_{\text{perc}}$ ▷ Compute generator loss
- 18: $m_i^g \leftarrow \beta_1 m_{i-1}^g + (1 - \beta_1) \nabla_g \mathcal{L}_g$
- 19: $v_i^g \leftarrow \beta_2 v_{i-1}^g + (1 - \beta_2) (\nabla_g \mathcal{L}_g)^2$
- 20: $\hat{m}_i^g \leftarrow \frac{m_i^g}{1 - \beta_1^i}$
- 21: $\hat{v}_i^g \leftarrow \frac{v_i^g}{1 - \beta_2^i}$
- 22: $\theta_g^i \leftarrow \theta_g^{i-1} - \eta_g \frac{\hat{m}_i^g}{\sqrt{\hat{v}_i^g} + \epsilon}$ ▷ Update generator g using Adam optimizer
- 23: **end for**
- 24: **end for**




F.2.1. ábra. PSNR és SSIM értékek alakulása a tanítás során.


F.3. Kiértékelés eredmények



F.3.1. ábra. Rekonstruált jóindulatú elváltozások összehasonlítása, ahol a felső sorban Kim és Hong [16] eredményei, középen az eredeti képek, az alsó sorban pedig a dolgozat eredményei láthatóak.



F.3.2. ábra. Rekonstruált rosszindulatú elváltozások összehasonlítása, ahol a felső sorban Kim és Hong [16] eredményei, középen az eredeti képek, az alsó sorban pedig a dolgozat eredményei láthatóak.



F.3.3. ábra. Rekonstruált elváltozások összehasonlítása, ahol a felső sorban Lee és You [31] eredményei, középen az eredeti képek, az alsó sorban pedig a dolgozat eredményei láthatóak.

	Lee és You (saját)	Lee és You (bőrgyógyászok)	javasolt módszer (bőrgyógyászok)
Nem diagnosztizálható	-	2	0
Nehezen diagnosztizálható	-	1	2
Diagnosztizálható, de kompromisszumokkal	-	8	9
Nagyon jól diagnosztizálható	-	4	17
Tökéletesen diganosztizálható	-	0	2
MOS	4,18 (0,91)	2,93 (0,86)	3,63 (0,5)

F.2. táblázat. Lee és You MOS értékeival való összehasonlítás.