

# Denoising with Kernel Prediction and Asymmetric Loss Function

THIJS VOGELS, FABRICE ROUSSELLE, BRIAN  
MCWILLIAMS, GERHARD RÖTHLIN, ALEX HARVILL,  
DAVID ADLER, MARK MEYER, JAN NOVÁK

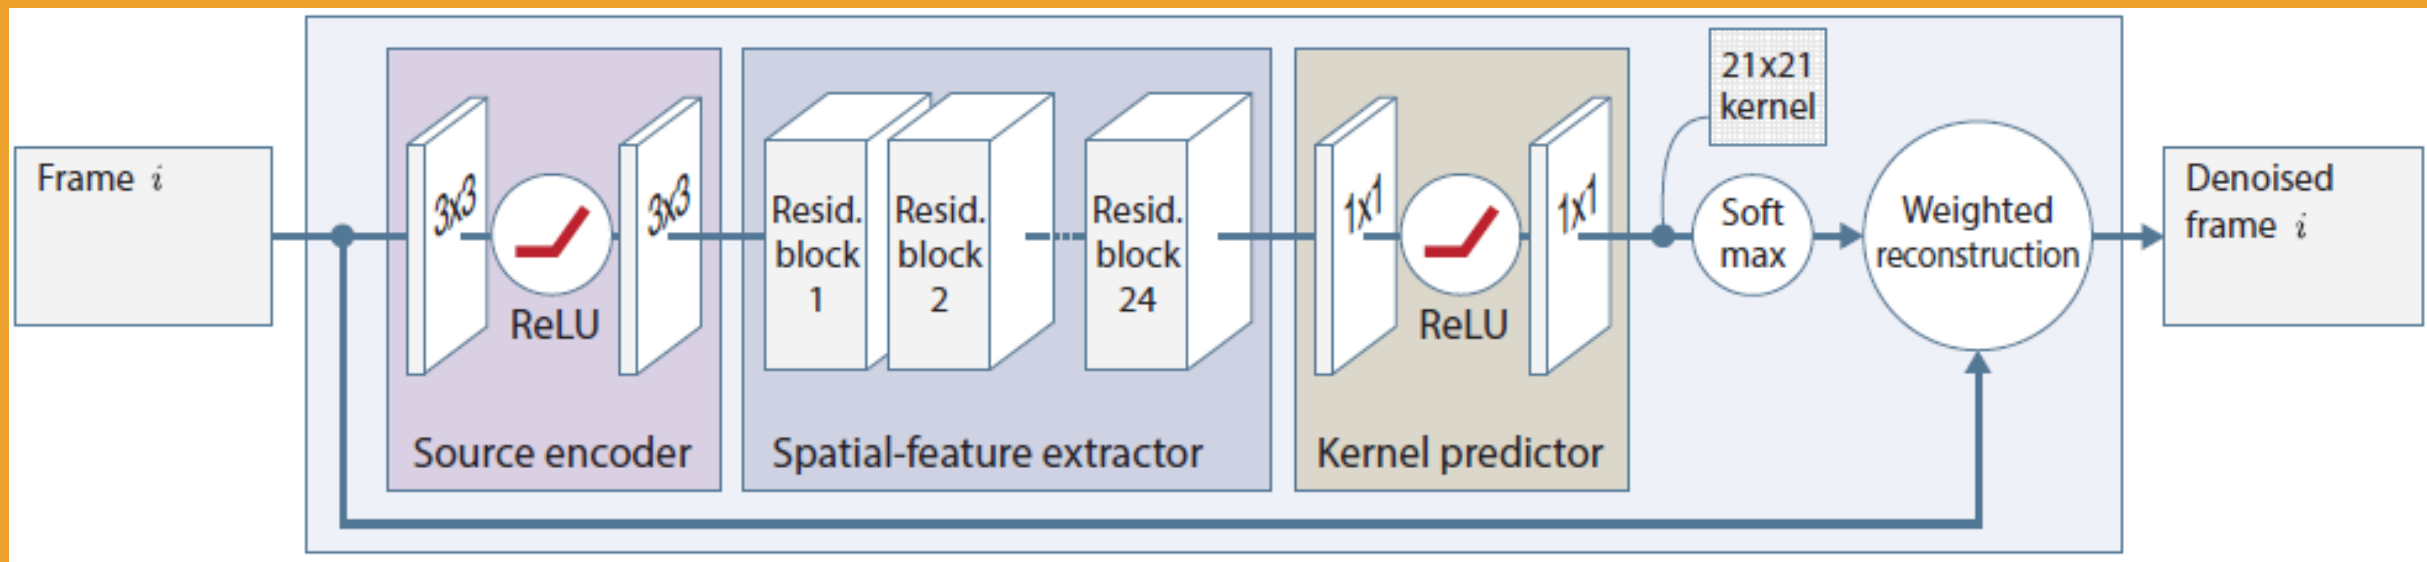




- Malé množstvo vzoriek spôsobuje šum
- Veľa vzoriek sa renderuje príliš pomaly
- Riešením je odšumovanie



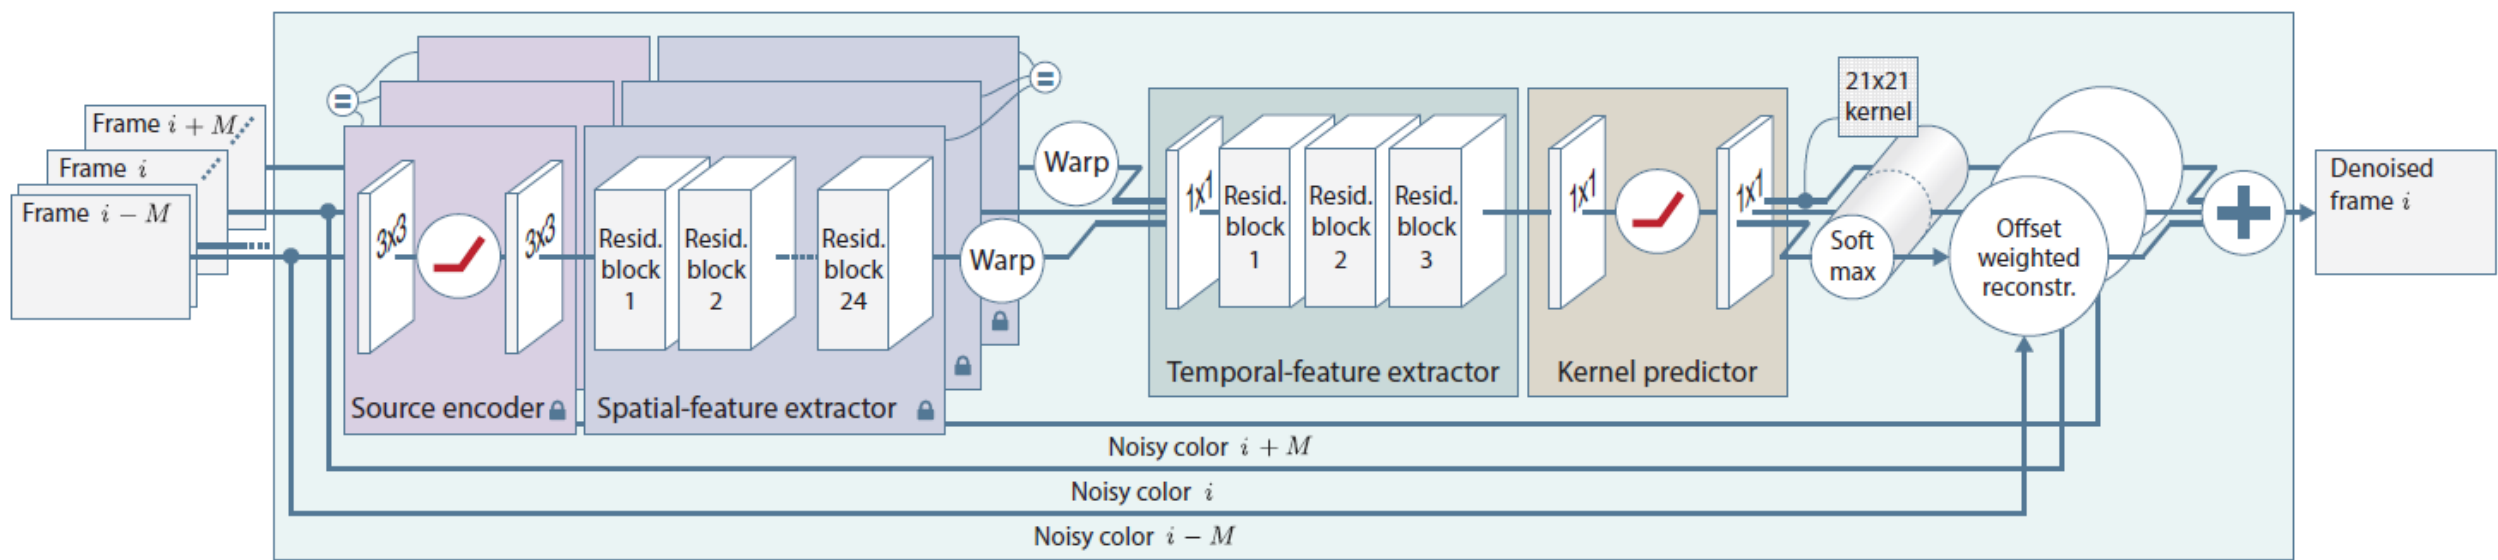
# Architektúra neurónovej siete pri odšumovaní jedného obrázku



- Source encoder
- Feature extractor
- Kernel predictor



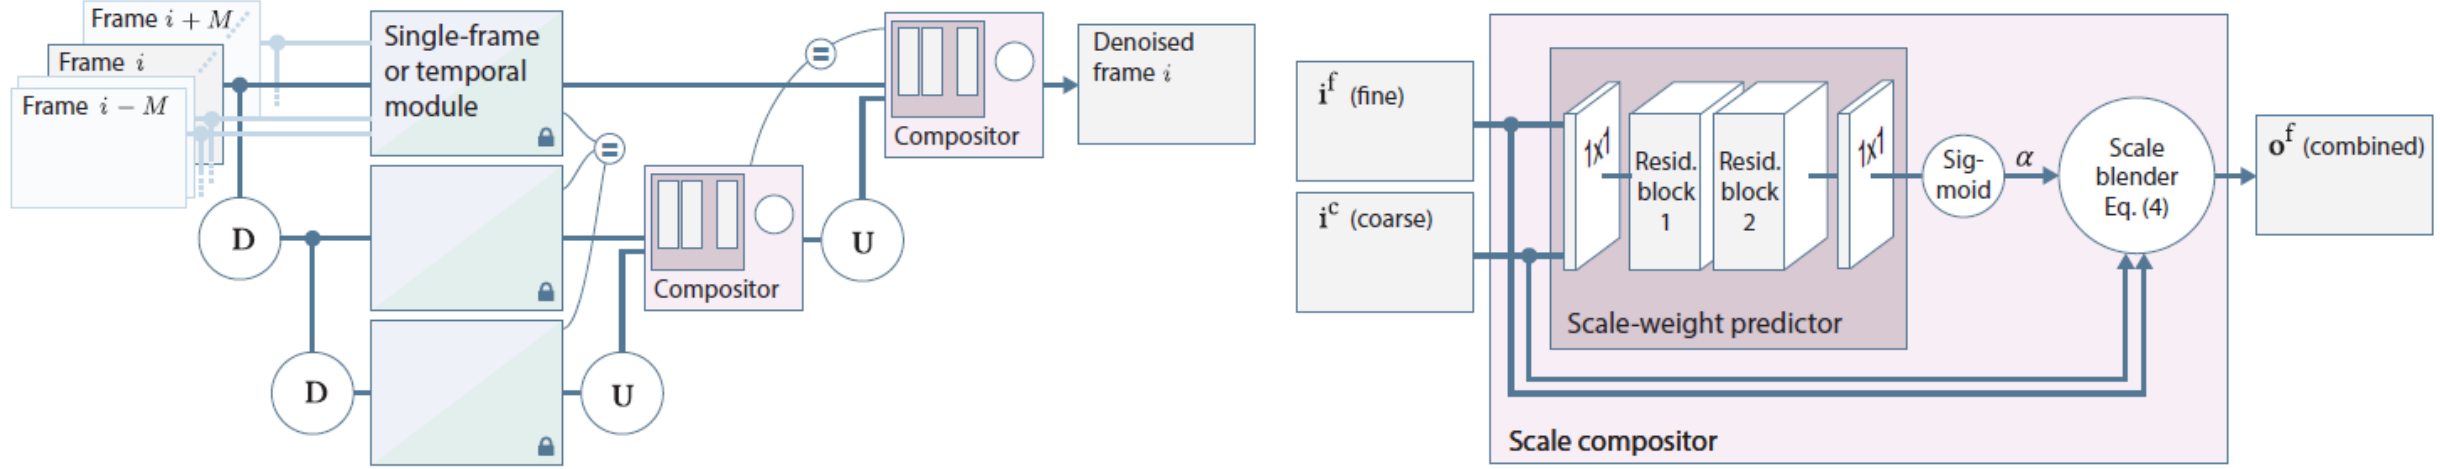
# Odšumovanie sekvencie obrázkov, dočasná stabilita



- Odšumovanie snímok po snímku vyvoláva blikanie v obraze
- Odstrániť sa dá tak, že berieme do úvahy aj okolité snímky toho snímku, ktorý odšumujeme
- Treba upraviť architektúru siete



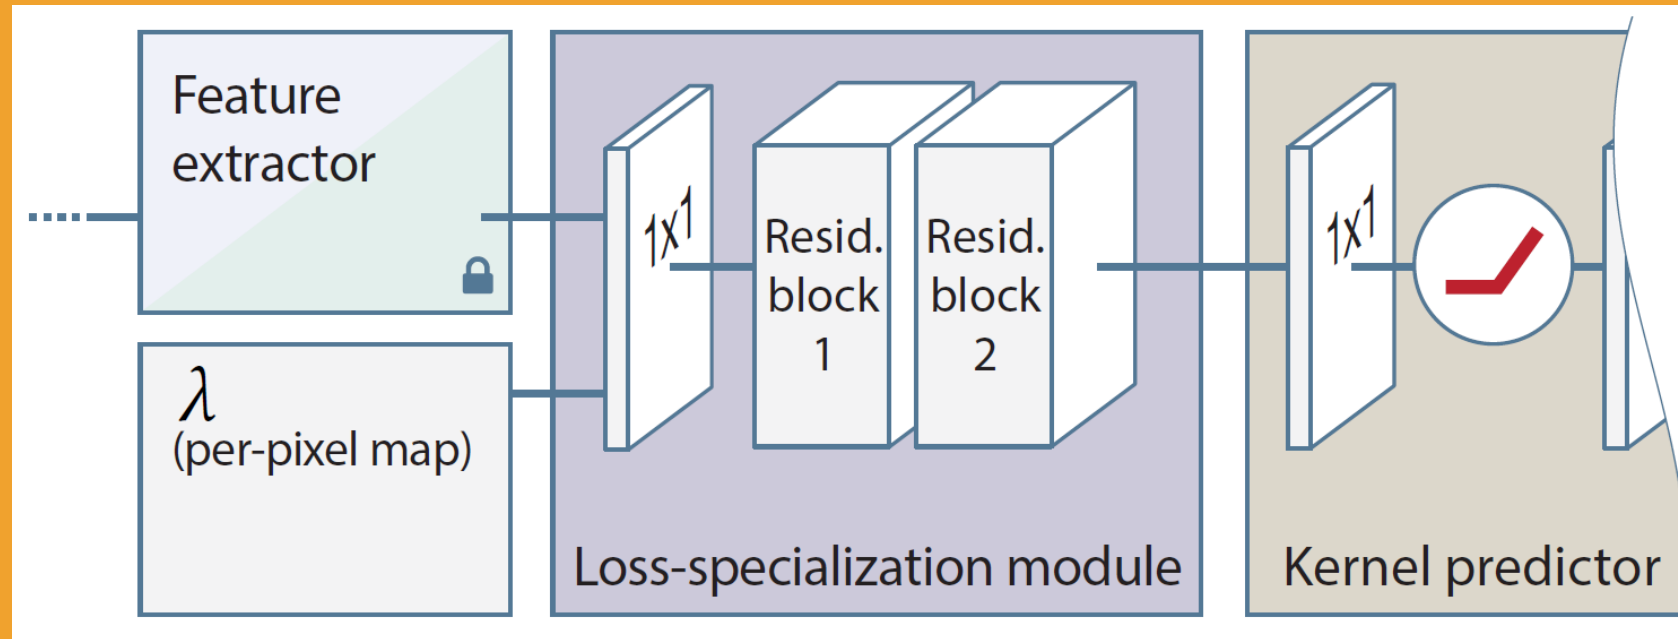
# Odstraňovanie nízkofrekvenčného šumu



- Použitie viacerých škál pomocou podvzorkovania obrázku
- Predikcia jadra a odšumenie každej škály zvlášť
- Následná kompozícia pomocou neurónovej siete
- Nízke frekvencie originálneho obrázku sú čiastočne nahradené nízkymi frekvenciami z podvzorkovaných verzií



# Asymetrická chybová funkcia



- Je dôležitá pre kontrolu miery vyhladenia
- Parameter  $\lambda$  určuje, nakoľko je sieť penalizovaná za výstup, ktorý je príliš vzdialený od vstupu
- Úprava architektúry tak, aby sa natrénovala pre rôzne hodnoty  $\lambda$  naraz



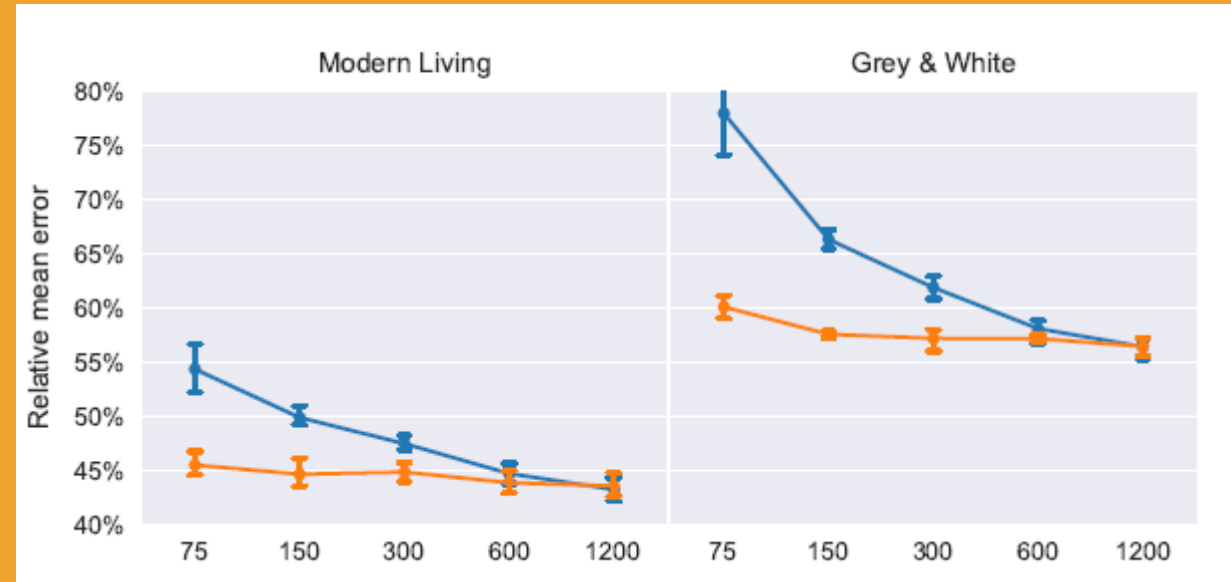
# Adaptívne vzorkovanie

- Rozloženie vzoriek je dôležité
- Jednoduchá neurónová sieť predikuje chybu jednotlivých pixlov
- Vzorkovanie prebieha iteratívne
- V každej iterácii sa pomocou siete odhadne chyba v jednotlivých pixloch
- Pixle s veľkou chybou dostanú v ďalšej iterácii väčší podiel vzoriek



# Experiment – kódovač vstupov

DSSIM (rel.)	Hyperion		RenderMan	
	MOANA	OLAF	CARS	Coco
Trained on MOANA only	13.31%	5.25%	18.89%	18.68%
Trained on CARS only	21.08%	8.67%	7.89%	12.25%
Trained on both	13.19%	5.05%	7.97%	12.43%
Trained on both w/ encoders	12.91%	5.07%	7.87%	12.18%

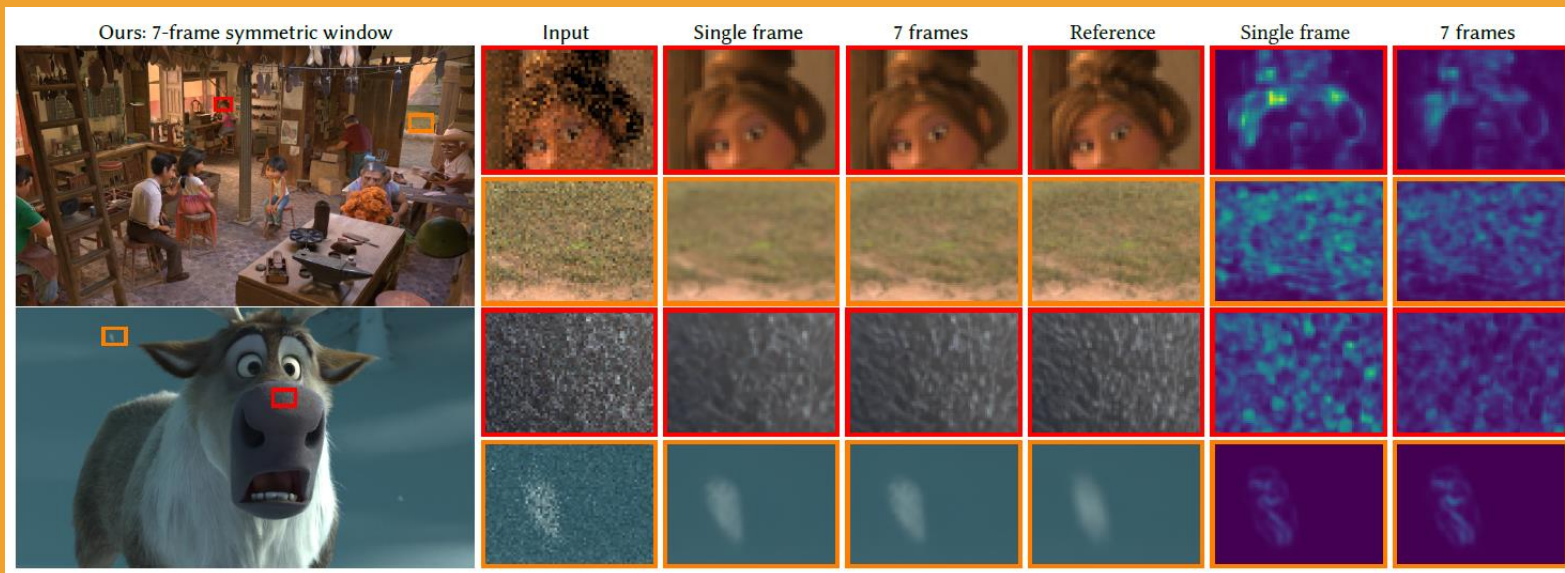
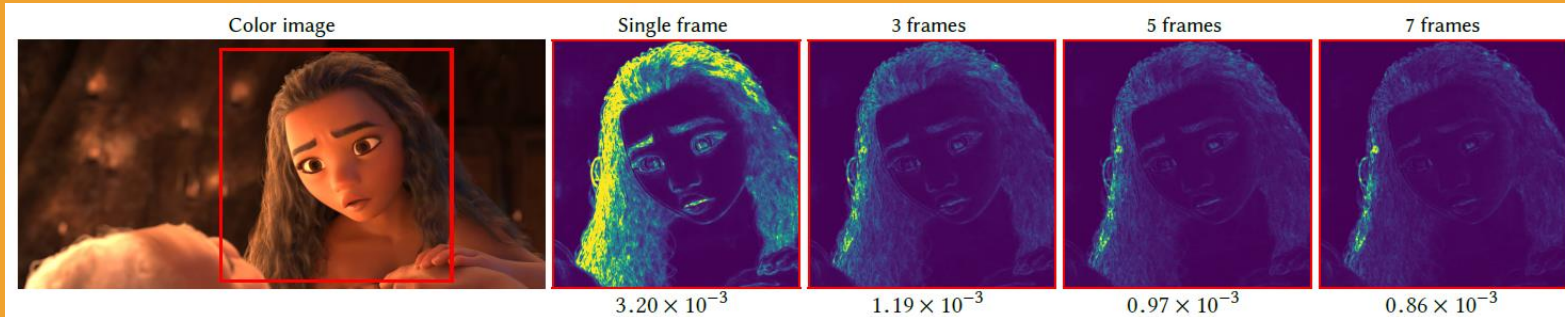


- Prebehli dva testy kódovača vstupov
- Prvý test ukazuje, že sieť natrénovaná iba na obrázkoch z jedného datasetu nie je schopná úspešne odšumiť obrázky z druhého datasetu
- Druhý test ukazuje, ako tréning kódovača vstupov urýchli adaptáciu siete na nový dataset





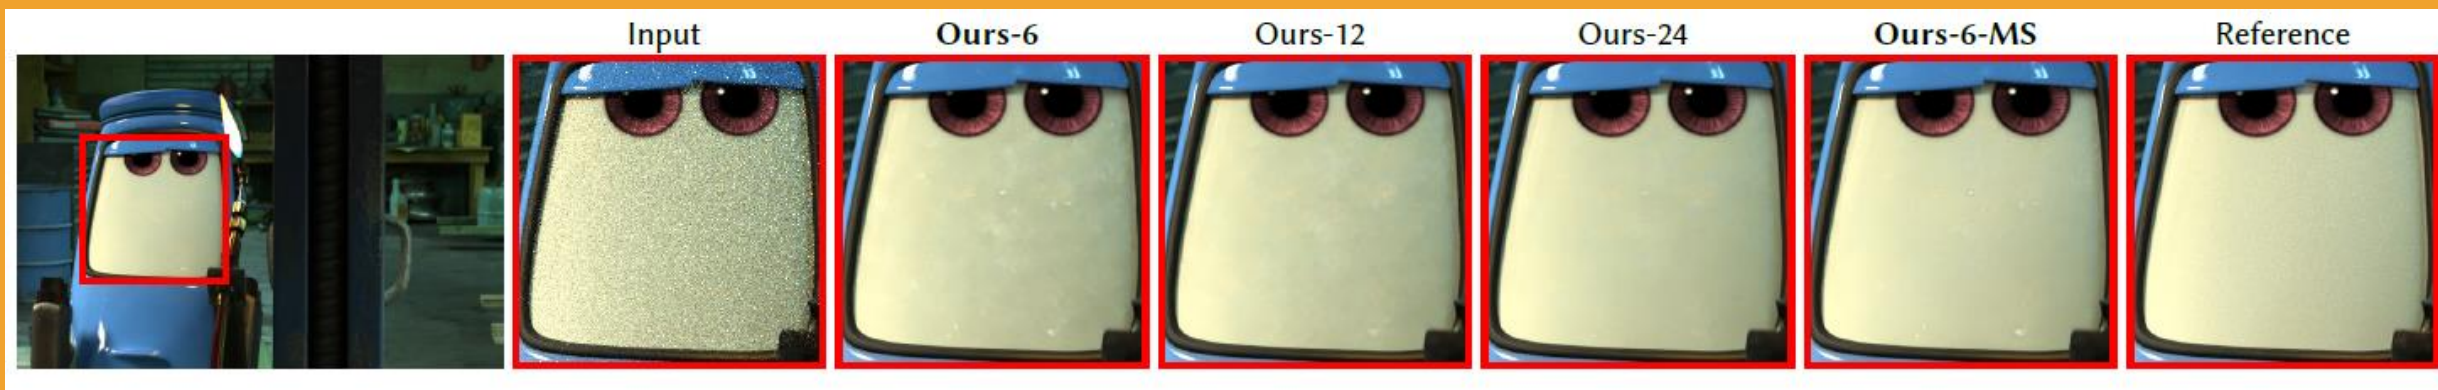
# Experiment – dočasná stabilita



- Testovanie presnosti odšumenia v závislosti od veľkosti okolia odšumovaného snímku
- S rastúcim okolím sa znižujú rozdiely medzi susednými snímkami
- Zároveň stúpa presnosť odšumenia statických regiónov




# Experiment – odstránenie nízkofrekvenčného šumu



- S rastúcou hĺbkou siete vidíme, ako klesá množstvo zostatkového nízkofrekvenčného šumu
- Pri použití metódy viacerých škál však stačí aj jednoduchšia architektúra a už použitie 6 reziduálnych blokov poskytuje uspokojivé výsledky
- Metóda viacerých škál je preto vhodná najmä v prípade nedostatku času, či výpočtovej pamäte











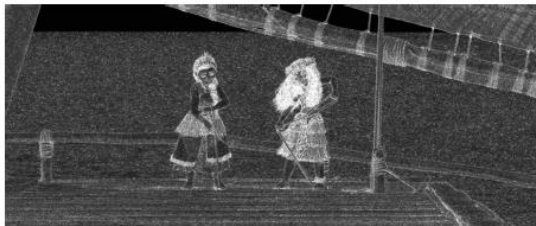
# Experiment – asymetrická chybová funkcia



- Závislosť výstupu od parametra  $\lambda$
- S rastúcou hodnotou  $\lambda$  rastie aj množstvo zostatkového šumu v obrázku
- Pri príliš malej hodnote  $\lambda$  však môžeme pozorovať stratu niektorých detailov v obraze



# Experiment – adaptívne vzorkovanie

	Predicted sampling	Groundtruth sampling
 DSSIM   MrSE	 62.4%   57.9%	 58.5%   54.1%
 DSSIM   MrSE	 88.3%   80.1%	 82.1%   73.5%
 DSSIM   MrSE	 103.4%   88.4%	 94.3%   80.3%

- Sieť bola trénovaná tak, aby predikovala chybovú mieru SMAPE
- Odšumené obrázky boli hodnotené mierami DSSIM a MrSE
- Percento pod obrázkom je podiel chyby adaptívneho a rovnomerného vzorkovania



