



## Zadání bakalářské práce

<b>Název:</b>	Statistická analýza vizuálních dimenzí vzhledu materiálů
<b>Student:</b>	Veronika Vilímovská
<b>Vedoucí:</b>	Ing. Jiří Filip, Ph.D.
<b>Studijní program:</b>	Informatika
<b>Obor / specializace:</b>	Znalostní inženýrství
<b>Katedra:</b>	Katedra aplikované matematiky
<b>Platnost zadání:</b>	do konce letního semestru 2023/2024

### Pokyny pro vypracování

Tato práce je zaměřena na hledání statistických vlastností popisujících vizuální dimenze běžných materiálů. Toto umožní intuitivní vyhledávání materiálu dle vizuálních kritérií napříč různými reprezentacemi jeho vzhledu (textura, odrazivostní model, BRDF, BTF). Pro účely analýzy bude využita pokročilá reprezentace vzhledu materiálů BTF. Cílem této práce je na základě dostupných výsledků psychovizuální studie co nejvíce omezit množství snímků, pro různé směry osvětlení a pohledu, potřebných k zachycení hlavních vizuálních vlastností vzhledu materiálů reprezentovaných pomocí výpočetních statistik.

1. Proveďte rešerši v oblastech (a) reprezentace vzhledu materiálů a (b) metod strojového učení pro zachycení jejich vizuálních charakteristik.
2. Na vstupní sadě BTF dat skupiny materiálů (dodá vedoucí práce) určete vhodné výpočetní statistiky korelující s poskytnutými psychovizuálními daty (dodá vedoucí práce).
3. Za použití statistických metod a metod strojového učení omezte množství potřebných snímků tak, aby sledované statistiky (např. histogramy intenzit, barevného podání, frekvencí) zůstaly co nejvíce zachovány.
4. Vyhodnoťte a diskutujte rozdíly pro materiál reprezentovaný pomocí kompletních dat a pomocí vybrané podmnožiny.
5. Implementaci proveďte v jazyce Python (případně v kombinaci s C++/Matlab).



Bakalářská práce

# STATISTICKÁ ANALÝZA VIZUÁLNÍCH DIMENZÍ VZHLEDU MATERIÁLŮ

Veronika Vilímovská

Fakulta informačních technologií  
Katedra aplikované matematiky  
Vedoucí: Ing. Jiří Filip, Ph.D.  
11. května 2023

České vysoké učení technické v Praze  
Fakulta informačních technologií

© 2023 Veronika Vilímovská. Všechna práva vyhrazena.

*Tato práce vznikla jako školní dílo na Českém vysokém učení technickém v Praze, Fakultě informačních technologií. Práce je chráněna právními předpisy a mezinárodními úmluvami o právu autorském a právech souvisejících s právem autorským. K jejímu užití, s výjimkou bezúplatných zákonných licencí a nad rámec oprávnění uvedených v Prohlášení, je nezbytný souhlas autora.*

Odkaz na tuto práci: Vilímovská Veronika. *Statistická analýza vizuálních dimenzí vzhledu materiálů*. Bakalářská práce. České vysoké učení technické v Praze, Fakulta informačních technologií, 2023.



## Obsah

Poděkování	x
Prohlášení	xi
Abstrakt	xii
Seznam zkratek	xiii
Úvod	1
<b>1 Problematika reprezentace materiálů</b>	<b>3</b>
1.1 Modely reprezentace vzhledu materiálů . . . . .	3
1.1.1 General Reflectance Function . . . . .	4
1.1.2 Modely homogenních materiálů . . . . .	4
1.1.3 Modely materiálů s texturou . . . . .	5
1.2 Metody strojového učení pro zachycení vizuálních charakteristik . . . . .	8
1.2.1 Pravděpodobnostní modely . . . . .	8
1.2.2 Metody lineární dekompozice . . . . .	9
1.2.3 Odrazivostní modely pracující po pixelech . . . . .	10
1.2.4 Přístupy k modelaci na základě vzoru . . . . .	12
1.2.5 Metody hlubokého učení . . . . .	13
1.3 Lidské vnímání materiálů . . . . .	15
1.3.1 Vnímání materiálů ve formě fotografií . . . . .	15
1.3.2 Vnímání materiálu ve formě objektů . . . . .	17
1.4 Návaznost na předchozí práce . . . . .	17
<b>2 Teoretické zázemí</b>	<b>19</b>
2.1 Definice výpočetních statistik . . . . .	19
2.1.1 Maximum . . . . .	19
2.1.2 Minimum . . . . .	19
2.1.3 Průměr . . . . .	20
2.1.4 Rozptyl . . . . .	20
2.1.5 Šikmost (Skewness) . . . . .	20
2.1.6 Špičatost (Kurtosis) . . . . .	21
2.1.7 Nízké, střední a vysoké frekvence . . . . .	21
2.1.8 Směrovost . . . . .	22
2.1.9 Barevnost (Chroma) . . . . .	24
2.2 Použité metody zjištění informací o datasetu . . . . .	24
2.2.1 Korelace . . . . .	24
2.2.2 Analýza hlavních komponent (PCA) . . . . .	25
2.3 Použité modely strojového učení . . . . .	26
2.3.1 Lineární regrese . . . . .	26
2.3.2 Hřebenová regrese . . . . .	26
2.4 Metody evaluace modelů . . . . .	27

2.4.1	Použité metriky validace . . . . .	27
2.4.2	Validační množina . . . . .	28
2.4.3	Křížová validace . . . . .	28
2.5	Barevné prostory . . . . .	29
2.6	Použité metriky vzdálenosti snímků . . . . .	29
2.6.1	Euklidovská vzdálenost . . . . .	30
2.6.2	$\Delta E$ . . . . .	30
2.7	Sledované statistiky . . . . .	30
2.7.1	Vizuální porovnání . . . . .	30
2.7.2	Práh vzdálenosti . . . . .	31
2.7.3	Histogram . . . . .	31
<b>3</b>	<b>Popis dat</b>	<b>33</b>
3.1	Použitá měření vzhledu materiálů . . . . .	33
3.1.1	Uniformní BTF data . . . . .	33
3.1.2	BTF data pro vizuální experiment . . . . .	35
3.2	Vizuální experimenty a získaná data . . . . .	36
<b>4</b>	<b>Analýza řešení problému</b>	<b>39</b>
4.1	Návrh výpočetních statistik, jejich analýza a výběr . . . . .	40
4.1.1	Výběr statistik . . . . .	40
4.1.2	Analýza statistik . . . . .	41
4.1.3	Generalizace vlastností statistik . . . . .	41
4.2	Mapování statistik na vizuální hodnocení a jeho predikce . . . . .	42
4.3	Výběr vizuálně podstatných dat . . . . .	42
4.4	Aplikace výsledků na kompresi dat . . . . .	44
4.5	Validace aplikace statistik . . . . .	45
<b>5</b>	<b>Praktická část</b>	<b>47</b>
5.1	Analýza dat . . . . .	48
5.1.1	Analýza snímků videa . . . . .	48
5.1.2	Analýza směrovosti a frekvencí . . . . .	51
5.1.3	Porovnání histogramů . . . . .	54
5.1.4	Korelace statistik a PCA analýza . . . . .	55
5.1.5	Korelace s vizuálními hodnoceními . . . . .	56
5.2	Mapování výpočetních statistik na vizuální hodnocení . . . . .	58
5.2.1	Příprava dat . . . . .	58
5.2.2	Křížová validace . . . . .	58
5.2.3	Validace pomocí validační množiny . . . . .	62
5.2.4	Výsledek mapování . . . . .	65
5.3	Výběr vizuálně podstatných dat a komprese dat . . . . .	66
5.3.1	Příprava dat . . . . .	66
5.3.2	Analýza vzdálenostních matic a prahů vzdálenosti . . . . .	67
5.3.3	Výběr dat a komprese . . . . .	69
<b>6</b>	<b>Analýza výsledků</b>	<b>73</b>
6.1	Validace aplikace statistik . . . . .	73
6.1.1	Vizuální porovnání . . . . .	73
6.1.2	Práh vzdálenosti . . . . .	76
6.1.3	Porovnání histogramů . . . . .	76
6.2	Závěrečné vyhodnocení použitých metod komprese . . . . .	78
6.3	Další plánovaný výzkum . . . . .	79

Obsah

v

**Závěr** 81

**A Příloha** 83

**Obsah přiloženého archivu** 101

## Seznam obrázků

1	Schéma postupu práce. . . . .	2
2.1	Amplitudové spektrum Fourierovy transformace snímku. . . . .	22
2.2	Frekvenční výkonová spektrální hustota a průměrné hodnoty frekvencí materiálu 1. . . . .	22
2.3	Postup Fourierovy transformace a ořezu hodnot do půlkruhu. . . . .	23
2.4	Matice DFPCM zobrazující hodnoty amplitud v jednotlivých sektorech. . . . .	23
3.1	Ilustrační snímky materiálů mimo odlesk. Obrázek poskytl vedoucí práce. . . . .	34
3.2	Ilustrační snímky materiálů v odlesku. Obrázek poskytl vedoucí práce. . . . .	34
3.3	Měřené pozice osvětlení a kamery. Zdroj: [94] . . . . .	35
3.4	Postupné otočení materiálu do odlesku. . . . .	35
3.5	Ukázka průběhu experimentu. . . . .	37
4.1	Schéma postupu práce. . . . .	39
4.2	Vzdálenostní matice Euklidovské vzdálenosti statistik prvního materiálu. . . . .	43
5.1	Schéma postupu práce. . . . .	47
5.2	Reference mimo odlesk. . . . .	48
5.3	Reference v odlesku. . . . .	48
5.4	Průběh hodnoty průměru přes 60 snímků pro 30 materiálů. . . . .	49
5.5	Průběh hodnoty maxima přes 60 snímků pro 30 materiálů. . . . .	49
5.6	Průběh hodnoty minima přes 60 snímků pro 30 materiálů. . . . .	50
5.7	Průběh hodnoty rozptylu přes 60 snímků pro 30 materiálů. . . . .	50
5.8	Průběh hodnoty barevnosti přes 60 snímků pro 30 materiálů. . . . .	51
5.9	Směrnost snímků 9 a 51 přes všechny materiály. . . . .	52
5.10	Průměrná amplituda nízkých frekvencí snímků 9 a 51 přes všechny materiály. . . . .	52
5.11	Průměrná amplituda středních frekvencí snímků 9 a 51 přes všechny materiály. . . . .	53
5.12	Průměrná amplituda vysokých frekvencí snímků 9 a 51 přes všechny materiály. . . . .	53
5.13	Ukázkový graf dvou porovnávaných histogramů. . . . .	54
5.14	Rozdíl histogramů videa a jednoho směru BTF dat podle $\chi^2$ a <i>Kolmogorovy-Smirnovovy odchylky</i> . . . . .	54
5.15	Korelace výpočetních statistik mezi sebou pro průměrnou hodnotu ze všech snímků videa přes všechny materiály. . . . .	55
5.16	Singulární hodnoty PCA analýzy. . . . .	56
5.17	Kumulativní suma vysvětleného rozptylu jednotlivými PCA komponentami. . . . .	56
5.18	Korelace průměru s hodnocením statistik <i>světlost</i> , <i>kontrast</i> , <i>barevnost</i> pro 60 snímků přes všechny materiály. . . . .	57
5.19	Korelace rozptylu s hodnocením statistik <i>světlost</i> , <i>kontrast</i> , <i>barevnost</i> pro 60 snímků přes všechny materiály. . . . .	57
5.20	Korelace šikmosti s hodnocením statistik <i>světlost</i> , <i>kontrast</i> , <i>barevnost</i> pro 60 snímků přes všechny materiály. . . . .	57
5.21	Korelace špičatosti s hodnocením statistik <i>světlost</i> , <i>kontrast</i> , <i>barevnost</i> pro 60 snímků přes všechny materiály. . . . .	58

5.22	R2 skóre lineární regrese plné množiny výpočetních statistik vysvětlující jednotlivé vizuální statistiky validované pomocí křížové validace. . . . .	59
5.23	RMSE skóre lineární regrese plné množiny výpočetních statistik vysvětlující jednotlivé vizuální statistiky validované pomocí křížové validace. . . . .	60
5.24	Zlepšení (modré) a zhoršení (červené) R2 skóre při lineární regresi omezené množiny statistik validované pomocí křížové validace. . . . .	60
5.25	Zlepšení (modré) a zhoršení (červené) RMSE skóre při lineární regresi omezené množiny statistik validované pomocí křížové validace. . . . .	60
5.26	R2 skóre hřebenové regrese plné množiny výpočetních statistik vysvětlující jednotlivé vizuální statistiky s nejlepším parametrem alfa přes všechny vizuální statistiky validované pomocí křížové validace. . . . .	61
5.27	RMSE skóre hřebenové regrese plné množiny výpočetních statistik vysvětlující jednotlivé vizuální statistiky s nejlepším parametrem alfa přes všechny vizuální statistiky validované pomocí křížové validace. . . . .	61
5.28	R2 skóre hřebenové regrese omezené množiny výpočetních statistik vysvětlující jednotlivé vizuální statistiky s nejlepším parametrem alfa přes všechny vizuální statistiky validované pomocí křížové validace. . . . .	62
5.29	RMSE skóre hřebenové regrese omezené množiny výpočetních statistik vysvětlující jednotlivé vizuální statistiky s nejlepším parametrem alfa přes všechny vizuální statistiky validované pomocí křížové validace. . . . .	62
5.30	R2 skóre lineární regrese vysvětlující jednotlivé vizuální statistiky validované pomocí validační množiny. . . . .	63
5.31	RMSE skóre lineární regrese vysvětlující jednotlivé vizuální statistiky validované pomocí validační množiny. . . . .	63
5.32	R2 skóre hřebenové regrese vysvětlující jednotlivé vizuální statistiky s nejlepším parametrem alfa přes všechny vizuální statistiky validované pomocí validační množiny. . . . .	64
5.33	RMSE skóre hřebenové regrese vysvětlující jednotlivé vizuální statistiky s nejlepším parametrem alfa přes všechny vizuální statistiky validované pomocí validační množiny. . . . .	64
5.34	R2 skóre hřebenové regrese vysvětlující jednotlivé vizuální statistiky s nejlepším parametrem alfa pro každou vizuální statistiku zvlášť validované pomocí validační množiny. . . . .	65
5.35	RMSE skóre hřebenové regrese vysvětlující jednotlivé vizuální statistiky s nejlepším parametrem alfa pro každou vizuální statistiku zvlášť validované pomocí validační množiny. . . . .	65
5.36	R2 skóre výsledného vybraného modelu na testovací množině dat. . . . .	66
5.37	RMSE skóre výsledného vybraného modelu na testovací množině dat. . . . .	66
5.38	Poměr počtu nahrazených snímků a prahu $\Delta E$ vzdálenosti snímků pro materiál 1. . . . .	67
5.39	Poměr počtu nahrazených snímků a prahu Euklidovské vzdálenosti výpočetních statistik pro materiál 1. . . . .	68
5.40	Poměr počtu nahrazených snímků a prahu $\Delta E$ vzdálenosti snímků pro všechny materiály. . . . .	68
5.41	Poměr počtu nahrazených snímků a prahu Euklidovské vzdálenosti výpočetních statistik pro všechny materiály. . . . .	69
5.42	Mapa ponechaných snímků pro různé prahy vzdálenosti $\Delta E$ materiálu 1. Obrázek poskytl vedoucí práce. . . . .	70
5.43	Mapa ponechaných snímků pro různé prahy Euklidovské vzdálenosti výpočetních statistik materiálu 1. Obrázek poskytl vedoucí práce. . . . .	70

6.1	Vizualizace materiálu 1 z pozice 1 pro plná data a poté pro různé hodnoty ponechaných snímků (prahů) společně s rozdílovými snímky oproti plným datům, redukce dat pomocí $\Delta E$ metriky. Obrázek poskytl vedoucí práce. . . . .	74
6.2	Vizualizace materiálu 1 z pozice 1 pro plná data a poté pro různé hodnoty ponechaných snímků (prahů) společně s rozdílovými snímky oproti plným datům, redukce dat pomocí Euklidovské vzdálenosti statistik. Obrázek poskytl vedoucí práce. . . . .	74
6.3	Vizualizace materiálu 2 z pozice 2 pro plná data a poté pro různé hodnoty ponechaných snímků (prahů) společně s rozdílovými snímky oproti plným datům, redukce dat pomocí $\Delta E$ metriky. Obrázek poskytl vedoucí práce. . . . .	75
6.4	Vizualizace materiálu 2 z pozice 2 pro plná data a poté pro různé hodnoty ponechaných snímků (prahů) společně s rozdílovými snímky oproti plným datům, redukce dat pomocí Euklidovské vzdálenosti statistik. Obrázek poskytl vedoucí práce. . . . .	75
6.5	Histogram hodnot intenzity vizualizace s plnými daty a s redukovanými daty bez hodnot pozadí vizualizace pro materiál 1 v pozici 1 pro $\Delta E$ . . . . .	77
6.6	Histogram hodnot intenzity vizualizace s plnými daty a s redukovanými daty bez hodnot pozadí vizualizace pro materiál 1 v pozici 1 pro Euklidovskou vzdálenost výpočetních statistik. . . . .	77
A.1	Průběh hodnoty šikmosti přes 60 snímků pro 30 materiálů. . . . .	83
A.2	Průběh hodnoty špičatosti přes 60 snímků pro 30 materiálů. . . . .	84
A.3	Korelace průměru s hodnocením všech vizuálních statistik pro 60 snímků přes všechny materiály. . . . .	84
A.4	Korelace rozptylu s hodnocením vizuálních statistik pro 60 snímků přes všechny materiály. . . . .	85
A.5	Korelace šikmosti s hodnocením všech vizuálních statistik pro 60 snímků přes všechny materiály. . . . .	85
A.6	Korelace špičatosti s hodnocením vizuálních statistik pro 60 snímků přes všechny materiály. . . . .	86
A.7	Mapa ponechaných snímků pro různé prahy vzdálenosti $\Delta E$ materiálu 2. Obrázek poskytl vedoucí práce. . . . .	86
A.8	Mapa ponechaných snímků pro různé prahy Euklidovské vzdálenosti výpočetních statistik materiálu 2. Obrázek poskytl vedoucí práce. . . . .	86
A.9	Mapa ponechaných snímků pro různé prahy vzdálenosti $\Delta E$ materiálu 3. Obrázek poskytl vedoucí práce. . . . .	87
A.10	Mapa ponechaných snímků pro různé prahy Euklidovské vzdálenosti výpočetních statistik materiálu 3. Obrázek poskytl vedoucí práce. . . . .	87
A.11	Vizualizace materiálu 1 z pozice 2 pro plná data a poté pro různé hodnoty ponechaných snímků (prahů) společně s rozdílovými snímky oproti plným datům, redukce dat pomocí $\Delta E$ metriky. Obrázek poskytl vedoucí práce. . . . .	88
A.12	Vizualizace materiálu 1 z pozice 2 pro plná data a poté pro různé hodnoty ponechaných snímků (prahů) společně s rozdílovými snímky oproti plným datům, redukce dat pomocí Euklidovské vzdálenosti statistik. Obrázek poskytl vedoucí práce. . . . .	88
A.13	Vizualizace materiálu 2 z pozice 1 pro plná data a poté pro různé hodnoty ponechaných snímků (prahů) společně s rozdílovými snímky oproti plným datům, redukce dat pomocí $\Delta E$ metriky. Obrázek poskytl vedoucí práce. . . . .	89
A.14	Vizualizace materiálu 2 z pozice 1 pro plná data a poté pro různé hodnoty ponechaných snímků (prahů) společně s rozdílovými snímky oproti plným datům, redukce dat pomocí Euklidovské vzdálenosti statistik. Obrázek poskytl vedoucí práce. . . . .	89

A.15	Vizualizace materiálu 3 z pozice 1 pro plná data a poté pro různé hodnoty ponechaných snímků (prahů) společně s rozdílovými snímky oproti plným datům, redukce dat pomocí $\Delta E$ metriky. Obrázek poskytl vedoucí práce. . . . .	90
A.16	Vizualizace materiálu 3 z pozice 1 pro plná data a poté pro různé hodnoty ponechaných snímků (prahů) společně s rozdílovými snímky oproti plným datům, redukce dat pomocí Euklidovské vzdálenosti statistik. Obrázek poskytl vedoucí práce. . . . .	90
A.17	Vizualizace materiálu 3 z pozice 2 pro plná data a poté pro různé hodnoty ponechaných snímků (prahů) společně s rozdílovými snímky oproti plným datům, redukce dat pomocí $\Delta E$ metriky. Obrázek poskytl vedoucí práce. . . . .	91
A.18	Vizualizace materiálu 3 z pozice 2 pro plná data a poté pro různé hodnoty ponechaných snímků (prahů) společně s rozdílovými snímky oproti plným datům, redukce dat pomocí Euklidovské vzdálenosti statistik. Obrázek poskytl vedoucí práce. . . . .	91

## Seznam tabulek

5.1	Nejlepší hodnoty hyperparametru $\alpha$ hřebenové regrese pro různé vizuální dimenze validované pomocí validační množiny . . . . .	64
6.1	Prahy vzdálenosti snímků $\Delta E$ pro vybrané materiály a vybraný počet ponechaných snímků . . . . .	76
6.2	Prahy vzdálenosti snímků Euklidovské vzdálenosti výpočetních statistik pro vybrané materiály a vybraný počet ponechaných snímků . . . . .	76
6.3	$\chi^2$ vzdálenosti histogramů luminance snímků materiálu s plnou a s omezenou množinou dat . . . . .	78
A.1	Kolmogorova-Smirnovova odchylka histogramů luminance snímků materiálu s plnou a s omezenou množinou dat . . . . .	87

*Ráda bych poděkovala především panu Ing. Jiřímu Filipovi Ph.D. za vedení, trpělivost a ochotu při zpracovávání bakalářské práce. Dále bych chtěla poděkovat rodině, přátelům a příteli za podporu během celého studia.*



## Prohlášení

Prohlašuji, že jsem předloženou práci vypracovala samostatně a že jsem uvedla veškeré použité informační zdroje v souladu s Metodickým pokynem o dodržování etických principů při přípravě vysokoškolských závěrečných prací.

Beru na vědomí, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., autorského zákona, ve znění pozdějších předpisů, zejména skutečnost, že České vysoké učení technické v Praze má právo na uzavření licenční smlouvy o užití této práce jako školního díla podle § 60 odst. 1 citovaného zákona.

## Abstrakt

Tato bakalářská práce se zabývá statistickou analýzou vizuálních vlastností materiálů (konkrétně dřevěných dýh). V rešeršní části práce porovnávala různé formy reprezentací materiálů a metod strojového učení pro zachycení vizuálních charakteristik materiálů. V praktické části byly navrženy a analyzovány vhodné statistiky, které je možné vypočítat z digitální reprezentace materiálu. Následně se podařilo úspěšně namapovat navržené statistiky na lidské vnímání vlastností materiálu pomocí hřebenové regrese. Vybrané statistiky byly následně použity pro nalezení vizuálně podstatné části dat digitální reprezentace materiálu. Praktickou aplikací tohoto postupu je poté komprese BTF dat materiálu pouze na nalezenou podstatnou část. Výsledná komprimovaná reprezentace byla ohodnocena pomocí třech různých metod a ve všech se ukázalo, že komprese dostatečně zachovává vizuální vlastnosti materiálu.

**Klíčová slova** reprezentace materiálů, dřevo, BTF, komprese dat, strojové učení, regrese, statistická analýza, výpočetní statistiky, percepční statistiky, Python

## Abstract

This bachelor thesis deals with the statistical analysis of visual properties of materials (specifically wood veneers). The research part of the thesis compared different forms of material representations and machine learning methods for capturing visual characteristics of materials. In the practical part, suitable statistics that can be computed from the digital representation of the material were proposed and analyzed. Subsequently, the proposed statistics were successfully mapped to human perception of material properties using ridge regression. The selected statistics were then used to find the visually relevant part of the data of the digital representation of the material. A practical application of this procedure is then to compress the BTF material data to only the visually relevant part. The resulting compressed representation was evaluated using three different methods, and in all of them the compression was found to sufficiently preserve the visual properties of the material.

**Keywords** material representation, wood, BTF, data compression, machine learning, regression, statistical analysis, computational statistics, perceptual statistics, Python

## Seznam zkratek

BTF	Bidirectional Texture Function
BRDF	Bidirectional Reflectance Distribution Function
DFPCM	Discrete Fourier Plar Coordinates Matrix
GRF	General Reflectance Function
LAB	Luminance A B barevný prostor
LCH	Luminance Chroma Hue barevný prostor
PCA	Principal Component Analysis
PSD	Power Spectral Density
RGB	Red Green Blue barevný prostor
RMSE	Root Mean Square Error
SVBRDF	Spatially Varying Bidirectional Reflectance Distribution Function
XYZ	X Y Z barevný prostor



# Úvod

S vývojem technologií vzrůstá poptávka po virtuálních reprezentacích materiálů pomocí textur. Pro kvalitní reprezentaci je důležité, aby vlastnosti materiálů, které vnímáme při každodenním používání, byly věrně přeneseny do virtuálního prostředí. Textura je totiž, kromě tvaru, jedním z klíčových zdrojů informací pro lidské rozpoznávání objektů a jejich vlastností.

Nejčastější využití textur je v počítačové grafice pro modelování prostředí a objektů například v počítačových hrách či virtuálních světech. V širší oblasti průmyslu jako elektrotechnickém, stavebním, architektonickém či automobilním jsou textury využívány pro přesné přenesení vlastností materiálů do virtuálního prostředí. Například při tvorbě virtuálních modelů produktů, které je pak jednoduše možné představit v různých podmínkách osvětlení, úhlu pohledu či prostředí. [1]

První úlohou, kterou tato práce pomáhá řešit, je kategorizace a jednoduché vyhledávání materiálů a jejich vlastností. Zabývá se reprezentací materiálu pomocí měřitelných statistik a vztahem těchto statistik k lidskému vnímání. Pomocí těchto statistik bude poté možné vlastnosti materiálů řadit či filtrovat. V tomto ohledu práce navazuje na širší výzkum Ústavu teorie informace a automatizace Akademie věd (UTIA AV), který se zabývá vytvořením komplexního virtuálního otisku materiálu. Ten by měl být ideálně schopen zakódovat percepční vlastnosti materiálu po celý proces jeho virtuálního zpracování. Zjednodušil by tak proces vyhledávání a výběru správných materiálů s požadovanými percepčními vlastnostmi pro vizualizaci a případně i výrobu.

Druhou úlohou práce je zjednodušení procesu vizualizace a uchování digitálních verzí materiálů pomocí zmenšení objemu dat potřebného pro jeho datovou reprezentaci. Jsou zde představeny a porovnány 2 metody pro redukci dat na základě redundance informace. U jedné z metod je navíc redukce pomocí metod strojového učení navázána na výsledky lidského hodnocení vlastností materiálů. I když je při redukci ztracena část informace, zachová se část důležitá pro lidské vnímání. Nelze tak pouze okem rozpoznat rozdíl mezi materiálem reprezentovaným pomocí plných a redukováných dat.

Přesah práce do budoucna je poté v celkovém nahrazení lidského pozorovatele při identifikaci materiálů či objektů pomocí měřitelných statistik a strojového učení. Toho bude možné využít k automatické kompresi, kategorizaci či rychlému zjišťování informací o materiálu. Příkladem může být namíření fotoaparátu mobilního telefonu na materiál a následné okamžitým zobrazením jeho kategorie či přímo názvu společně s jeho vlastnostmi.

Cílem teoretické části bakalářské práce je:

- popis existujících modelů reprezentace vzhledu materiálů,
- popis metod strojového učení pro zachycení vizuálních charakteristik materiálů,
- definice výpočetních statistik počítaných na snímcích materiálu,

- popis sledovaných statistik, které budou v praktické části využity k hodnocení kvality aplikace výpočetních statistik k redukci dat.

Cílem praktické části bakalářské práce je:

- analýza a výběr množiny vhodných výpočetních statistik,
- mapování výpočetních statistik pomocí metod strojového učení na poskytnutá hodnocení vizuálních statistik materiálů,
- nalezení vizuálně důležitých dat modelu BTF pomocí různých metod počítání vzdálenosti snímků,
- využití vizuálně důležitých dat pro kompresi,
- porovnání rozdílů reprezentací materiálu pomocí všech dat a pomocí redukovanych dat.

První kapitola je věnována rešerši modelů reprezentace vzhledu materiálů a metod strojového učení pro zachycení vizuálních charakteristik. Na závěr je přidána část věnující se článkům zkoumajícím lidské vnímání materiálů a jsou popsány články, na které tato práce navazuje.

Druhá kapitola se věnuje teoretickému zázemí práce. Obsahuje definice veškeré teorie použité dále v práci konkrétně výpočetních statistik, metod analýzy dat, metod strojového učení a metod evaluace modelů. Kapitola popisuje použité barevné prostory a metriky použité pro výpočet vzdálenosti snímků. Na konci jsou definovány sledované statistiky, které budou použity pro ohodnocení redukce dat.

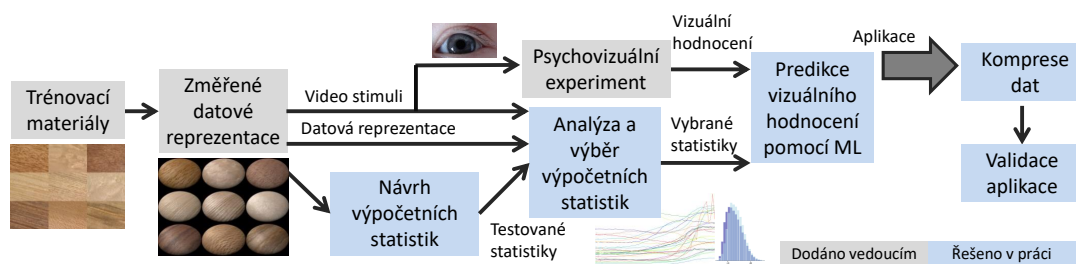
Třetí kapitola popisuje data, která jsou v práci použita.

Čtvrtá kapitola se věnuje samotnému postupu práce a analyzuje metody, které jsou v postupu použity.

Pátá kapitola popisuje implementaci postupu a průběžné výsledky jednotlivých kroků práce.

Šestá kapitola poté validuje výslednou kompresi, porovnává výsledky metod použitých v praktické části a zmiňuje směry, kterými by se výzkum tématu mohl dále ubírat.

V práci je postupováno na základě tohoto schématu:



■ **Obrázek 1** Schéma postupu práce.

## Kapitola 1

# Problematika reprezentace materiálů

*Tato kapitola je věnována rešerši konkrétních typů reprezentace materiálů, jejich výhodám a nevýhodám a způsobům využití. Jelikož se práce zabývá zachycením vlastností materiálů v elektronické podobě pomocí určitých charakteristik, je dále zařazena i kapitola věnující se metodám strojového učení, které různými metodami zachycují právě vizuální charakteristiky materiálů. Dále je zařazena část věnující se výzkumu lidského vnímání materiálů. Poslední část této kapitoly je věnována předchozímu výzkumu, rešerši prací, které se zabývají podobnou problematikou a na které může práce navazovat či odkazovat.*

### 1.1 Modely reprezentace vzhledu materiálů

Textura jako virtuální reprezentace materiálu nemá přesnou definici, dle [2] se ale lze odkázat k některým vlastnostem, které textury musí splňovat:

**Homogenita** – kovarianční funkce prostorových dat (spacial covariance function) se nemění s posunem

**Uniformní struktura** – textura se skládá z uniformně rozmístěných prvků (texely nebo texony) a toto rozmístění je přibližně stejné v celé oblasti textury

**Proměnlivá odrazivost** – textura je vyjádřená lokálně se měnící odrazivostí

**Závislost na škále** – vzhled textury se mění s rozlišením, působí hladce při nízkém a naopak velmi strukturovaně ve vysokém rozlišení

**Lokálnost** – textura je vlastností určité oblasti obrázku

**Materialita** – textura reprezentuje povrchový vzhled materiálu

Obecně je nejdůležitější to, že textura reprezentující materiál je homogenní a jedna její část obsahuje všechny frekvence, které se objevují ve všech dalších částech. Lze tedy z této jedné oblasti odhadnout, jak vypadá celkový vzhled materiálu.

Samotné realistické zobrazení fyzikálních vlastností materiálu textury je velmi obtížné a zároveň výpočetně náročné. Závisí na dopadu a odrazu světla od povrchu, které poté definují odlesky, barvu, a vzhled povrchu materiálu. Modely zachycující tyto informace o chování světla ve vztahu k pozici pozorovatele umožňují vizualizovat realistické chování ve všech možných podmínkách či síle osvětlení, úhlu pohledu či spektra. [3]

### 1.1.1 General Reflectance Function

Reálná odrazivost materiálu závisí mimo jiné na sférických úhlech dopadu a odrazu světla, času a spektru světla. Poskytuje tak komplexní informace o povrchu materiálu. Nejlepším, nejvíce deskriptivním a fyzikálně nejpřesnějším modelem je General Reflectance Function – GRF.

$$Y_r^{GRF} = GRF(\lambda_i, x_i, y_i, z_i, t_i, \theta_i, \varphi_i, \lambda_v, x_v, y_v, z_v, t_v, \theta_v, \varphi_v, \theta_t, \varphi_t)$$

Tato funkce je 16-dimenzionální, kde:

- $\lambda_i$  je hodnota spektra dopadajícího světla,
- $x_i, y_i, z_i$  jsou souřadnice místa, na něž dopadá světlo,
- $t_i$  je čas dopadu světla,
- $\omega_i = [\theta_i, \varphi_i]$  jsou sférické souřadnice úhlu dopadu,
- $\lambda_v$  je hodnota spektra pozorovaného odraženého světla,
- $x_v, y_v, z_v$  jsou souřadnice místa odrazu světla,
- $t_v$  je čas pozorování odraženého světla,
- $\omega_v = [\theta_v, \varphi_v]$  jsou sférické souřadnice úhlu odrazu,
- $\omega_t = [\theta_t, \varphi_t]$  úhel lomu světla prostupujícího dovnitř materiálu,

kde  $\theta$  reprezentuje elevaci a  $\varphi$  azimut sférických souřadnic.

Výhodou tohoto modelu je bezpochyby fyzikální přesnost, nejlépe popisuje reálné vlastnosti materiálu ale za cenu složitosti pro jakékoliv měření či modelace. Je možné, že v budoucnu budou vynalezeny měření či syntetizační modely, které zvládnou práci s GRF, prozatím je třeba se spokojit s používáním empirických modelů. Ty zjednodušují, aproximují výpočet, aby nebyl tolik výpočtetně náročný, ale zároveň zachovávají chtěné fyzikální vlastnosti.

Hlavní dvě skupiny empirických modelů se dělí podle toho, zda zachovávají strukturu povrchu či zda považují povrch za homogenní. [2]

### 1.1.2 Modely homogenních materiálů

Tato skupina využívá vlastnost textury závislost na škále. Hlavní zjednodušení spočívá v tom, že se uvažuje nízké rozlišení, což odpovídá pohledu na materiál z velké dálky. Poté se povrch jeví jako homogenní tedy nestrukturovaný a není třeba pracovat s žádnou složitou povrchovou texturou. Pokud zanedbáme tuto informaci o tom, že odrazivost světla je závislá na prostoru neboli že odrazivost je různá v různých částech materiálu, velmi tím zjednodušíme výpočty a modelování. [2]

Celkově tato aproximace lze popsat zjednodušenou GRF funkcí o 12 dimenzích:

$$Y_r^{GRF} = GRF(\lambda_i, z_i, t_i, \theta_i, \varphi_i, \lambda_v, z_v, t_v, \theta_v, \varphi_v, \theta_t, \varphi_t)$$

#### 1.1.2.1 BSDF

BSDF (Bidirectional Scattering Distribution Function) je nejobecnější model uvažující homogenní materiály. Tato funkce vrací najednou obě hodnoty rozptylu jak odraženého světla, tak lomeného světla procházejícího materiálem. Model je tedy 7-dimenzionální:

$$Y_r^{BSDF} = BSDF(\lambda, \theta_i, \varphi_i, \theta_v, \varphi_v, \theta_t, \varphi_t)$$



Výhodou tohoto modelu je přesnost, je to nejlepší aproximace GRF funkce při zanedbání textury povrchu. To je zároveň i nevýhodou, jelikož je stále příliš komplexní na běžné používání. [2]

Celkově se BSDF používá hlavně na generalizaci problému, kdy chceme spočítat jak odražené, tak pohlcené světlo. Reálně se problém potom dělí na další dva modely BRDF a BTDF, které uvažují pouze jednu z těchto složek světla – odražené (v případě BRDF) nebo lomené (v případě BTDF).

### 1.1.2.2 BRDF

BRDF (Bidirectional Reflectance Distribution Function) je jedním z nejznámějších a nejpoužívanějších modelů měření a virtualizace materiálu. Je zjednodušením předchozího BSDF s tím, že zanedbává lom světla dovnitř materiálu a naopak uvažuje světlo odražené. Model je 5-dimenzionální:

$$Y_r^{BRDF} = BRDF(\lambda, \theta_i, \varphi_i, \theta_v, \varphi_v),$$

ale má ještě další varianty jako 4-dimenzionální vzorec při zanedbání závislosti na vlnové délce nebo například Lambertian BRDF, které měří jen vlnovou délku a naopak osvětlení a pozorovatele uvažuje konstantní.

Výhodou tohoto modelu je zejména optimální reprezentace nestrukturovaného materiálu a to z toho pohledu, že zachovává dostatek dat při únosné výpočetní náročnosti. Díky velké využitelnosti existuje také velká podpora a mnoho navazujících modelů i již naměřených virtualizovaných materiálů. Samozřejmě nevýhodou je samotné zanedbání textury a zároveň zanedbání lomu a prostupu světla materiálem, což omezuje BRDF reprezentaci pouze na ploché a matné materiály. [2]

Zajímavé příklady použití tohoto modelu zahrnují například modelaci světla ve fotovoltaice. [4] Nebo použití vesmírnou agenturou NASA pro spektrometr (MODIS), který poskytuje informace o povrchu Země. [5] Nejčastější využití je poté v počítačové grafice při generování realistických scén.

### 1.1.2.3 BTDF

BTDF (Bidirectional Transmittance Distribution Function) model na rozdíl od BRDF zanedbává odražené světlo a popisuje světlo průchozí materiálem. Popisuje tedy průchod světla pro průhledné či částečně průhledné materiály. Je to také 5-dimenzionální model, ale místo odraženého popisuje průchozí světlo:

$$Y_r^{BTDF} = BTDF(\lambda, \theta_i, \varphi_i, \theta_t, \varphi_t)$$

Tento model je na rozdíl od BRDF dobrou vizualizací pro průsvitné a průhledné homogenní materiály. Nevýhodou je opět obecná homogenita materiálu, u tohoto modelu navíc ještě to, že měří pouze průchozí světlo. [2]

Zajímavým využitím BTDF může být např. měření rozptylových vlastností chemicky napařovaného selenidu zinečnatého [6] či použití vesmírnou agenturou NASA pro nastavení satelitních zařízení pro dálkový průzkum Země [7].

## 1.1.3 Modely materiálů s texturou

Tyto modely považují prostorovou informaci o textuře za důležitou. Zachovávají tedy prostorovou odrazivost a v tomto směru respektují modelaci pomocí GRF.

### 1.1.3.1 BSSRDF

BSSRDF (Bidirectional Surface Scattering Reflectance Distribution Function) je nejlepší aproximační funkcí GRF. Závisí na geometrii měřeného objektu. Ve větším měřítku lze pak mluvit o tzv. odrazivostních polích (reflectance fields), které jsou definovány na povrchu obklopujícím měřený objekt. Využívají se například při skenování lidského obličeje [8]. Oproti GRF je model pouze 9 dimenzionální:

$$Y_r^{BSSRDF} = BSSRDF(\lambda, x_i, y_i, \theta_i, \varphi_i, x_v, y_v, \theta_v, \varphi_v)$$

BSSRDF je momentálně stále velmi složitý model pro běžné měření a vizualizace [2], postupně již ale vznikají některé implementace [9]. Většinou se prakticky využívají hlavně jeho zjednodušení, použití samotné BSSRDF funkce je ale možné, např. [10] ji využívá pro realistickou modelaci srstí.

### 1.1.3.2 BRRTF

BRRTF (Bidirectional Reflectance and Transmittance Texture Function) je odrazivostní funkce, která vrací současně hodnoty pro lom i odrazivost světla na povrchu materiálu. Oproti BSSRDF tedy nezanebývá lom světla dovnitř materiálu při dopadu ale zase předpokládá odraz i lom příchozího světla na stejném místě, na které světlo dopadlo. Je tedy stejně jako BSSRDF 9-dimenzionální:

$$Y_r^{BRRTF} = BRRTF(\lambda, x_i, y_i, \theta_i, \varphi_i, \theta_v, \varphi_v, \theta_t, \varphi_t)$$

Jedná se o přijatelnou generalizaci modelu BTF, který se ale používá mnohem častěji. BRRTF je tedy nahraditelný modelem BTF a nemá příliš mnoho využití. [2]

### 1.1.3.3 BTF

BTF (Bidirectional Texture Function) je jeden ze dvou nejznámějších empirických modelů aproximace GRF, který lze zároveň měřit i poté modelovat, ačkoliv má poměrně velké nároky na modelaci a hardware. Model je 7-dimenzionální:

$$Y_r^{BRTTF} = BTF(\lambda, x, y, \theta_i, \varphi_i, \theta_v, \varphi_v)$$

Je možné vidět, že je jakousi kombinací aproximací předchozích dvou představených modelů. Předpokládá stejné místo dopadu a odrazu světla a zároveň zanebývá lom světla a jeho průchod materiálem v místě dopadu.

Nevýhodou kromě vysokých výpočetních nároků může být, že ačkoliv při měření zachytí efekty dějící se uvnitř materiálu, jako rozptyl světla či odrazy světla uvnitř materiálu, není schopný je oddělit od hodnot, které model využívá. Není tedy ani vhodný pro měření průhledných povrchů, jelikož zanebývá průchod světla materiálem. [2]

Další nevýhodou je velikost měřených dat, která dosahuje až několika GB. Tato velikost dat souvisí s velkou výhodou tohoto modelu. Umožňuje na rozdíl od dalšího velmi používaného BRDF pracovat právě s texturou, kterou při aproximaci nezanebává. Pro přesné zachycení textury na povrchu materiálu je ale potřeba měření z více různých úhlů pohledu a osvětlení, aby byly zachyceny všechny informace o struktuře. Ta se totiž projevuje ve formě jinak odraženého světla, které pak tvoří stíny v určitých částech textury. Pro přesné zachycení chování textury je tak potřeba více fotografií z více různých úhlů pohledu i světla, což poté navyšuje jak výpočetní náročnost, tak množství dat, které je pro model BTF potřeba ukládat. Existují ale již kompresní metody, které využívají redundanci dat. Jedním z cílů této práce je právě komprese BTF dat ale z pohledu lidského vnímání, neboli vyřazení některých úhlů pohledů a světla tak, že lidské vnímání nepozná rozdíl.

Hlavním využitím BTF modelu je realistická vizualizace materiálů v počítačové grafice, konkrétně např. ve virtuální realitě. Zajímavé využití v modelu biomedicíny je poté při modelování a rozpoznávání lidské kůže, představené v [11].

#### 1.1.3.4 SVBRDF

SVBRDF (Spatially Varying BRDF) je model podobný modelu BTF ale s omezeními platícími pro BRDF model. Tato omezení dostatečně zjednodušují základ BTF modelu pro jednodušší měření, oproti tomu ale zvyšují kompresi a zhoršují kvalitu výsledného měření. Jelikož BRDF je model zjednodušující představu o textuře na homogenní povrch, SVBRDF se hodí spíše pro měření téměř plochých povrchů. Zároveň má ale stejné omezení jako BTF, kdy zanedbává průchod světla materiálem, hodí se tedy spíše pro měření matných povrchů. Model je 7-dimenzionální:

$$Y_r^{SVBRDF} = SVBRDF(\lambda, x, y, \theta_i, \varphi_i, \theta_v, \varphi_v)$$

Lze ho popsat stejnými parametry jako BTF, představuje ale více omezení.

Výhodou tedy je zejména zjednodušení měření, komprese dat a jednodušší modelování oproti BTF při zachování jeho vlastností. Naopak nevýhodou ale může být zejména zhoršení kvality oproti BTF modelu, nemožnost modelace vnitřních dějů materiálu a velké omezení na ploché a matné materiály. [2]

Bylo provedeno několik studií, která zjednodušují zisk SVBRDF dat až na jednu či dvě fotografie. Práce [12] zjednodušuje modelování SVBRDF dat pouze na fotografii s bleskem a fotografií bez blesku. Dále byla provedena studie, která analyzuje zisk a modelování SVBRDF dat pouze z jediného snímku pořízeného mobilním telefonem [13]. SVBRDF data se také často používají jako data pro modely zachycující vizuální charakteristiky materiálů (1.2.3.3, 1.2.5.2).

#### 1.1.3.5 SLF

SLF(Surface Light Field) je model se zafixovaným úhlem dopadu světla od zdroje. Model je pouze 5-dimenzionální:

$$Y_r^{SLF} = SLF(\lambda, x, y, \theta_v, \varphi_v)$$

Jedná se o jednodušší BTF model, který zjednodušuje závislost na pozici přicházejícího světla. Není tedy možné modelovat materiál při různých úhlech osvětlení. [2]

V práci [14] je zmiňováno využití tohoto modelu pro modelování lesklých objektů za komplexních světelných podmínek.

#### 1.1.3.6 SRF

SRF(Surface Reflectance Field) podobný jako SLF, ale zafixovává pozici pozorovatele a tím úhly odrazu světla k pozorovateli. Je tedy stejně jako SLF 5-dimenzionální:

$$Y_r^{SRF} = SRF(\lambda, x, y, \theta_i, \varphi_i)$$

Opět se jedná o určité zjednodušení BTF modelu zanedbáním pozice pozorovatele při měření a modelování. Není tedy možné modelovat materiál při různých úhlech pohledu. [2]

#### 1.1.3.7 Multispektrální textura

Nejjednodušší a nejpoužívanější empirický model GRF. Multispektrální textura, podobně jako předchozí dva modely, fixuje úhly jak dopadajícího světla, tedy světelného zdroje, tak odraženého světla, tedy pozorovatele.

Může se jednat o model statické textury (ST), potom je 3-dimenzionální:

$$Y_r^{ST} = ST(\lambda, x, y)$$

Tento statický model je nejjednodušším modelem textury, je tedy jednoduchý pro použití v různých formách a pro různé účely. To je zároveň ale i nevýhodou, jelikož kvůli velkému zjednodušení ztrácí již hodně informace o textuře materiálu jako takové a o strukturách, které texturu tvoří. [2]

Nebo se může jednat o model dynamické textury (DT), potom je 4-dimenzionální:

$$Y_r^{DT} = DT(\lambda, x, y, t)$$

Jedná se o jediný používaný model dynamické textury. Je velmi podobný statickému modelu, ale umožňuje alespoň základní zachycení dynamického chování v čase. [2]

## 1.2 Metody strojového učení pro zachycení vizuálních charakteristik

Zachycení vizuálních charakteristik materiálu bylo v minulosti hojně studováno. Důležité je při reprezentaci zachovat dostatek informací o materiálu, aby byly zachovány jeho vlastnosti vnímané člověkem. Zároveň je ale potřeba zmenšit objem ukládaných dat do kompaktní podoby, kterou je možné dlouhodobě ukládat. Modely představované ve vědeckých pracích se o to pokouší různými způsoby – pomocí statistik, lineární dekompozicí, po jednotlivých pixelech, na základě vzoru či dnes velmi populárními neuronovými sítěmi. Tuto kompaktní reprezentaci je pak možné využít i pro syntézu umělých textur s požadovanými vlastnostmi.

Tato práce navazuje na některé tyto modely zejména při postupu reprezentace vlastností materiálu v kompaktní formě pomocí množiny statistik. Právě výběr těchto statistik byl proveden na základě existujících prací.

### 1.2.1 Pravděpodobnostní modely

Základem pravděpodobnostních modelů je představa textury jako pole homogenních částí, které se opakují, ale zároveň podléhají určité náhodnosti co se týče velikosti, barvy, orientace apod. Tato náhodná pole jsou poté zkoumána prostřednictvím statistických modelů, které se snaží popsat texturu konzistentně s lidským vnímáním.

Základní hypotézu o spojení textur a vizuálních statistik popsal jako první Julesz [15]. Texturu popsal jako reálné 2-dimenzionální homogenní náhodné pole s podmínkou existence množiny omezujících funkcí neboli statistik. Prvky z jakýchkoliv dvou náhodných polí jsou poté nerozeznatelné za určitých fixních podmínek porovnávání. Tato hypotéza nejen že definuje lidské vnímání jako hlavní hodnotící kritérium právě kritériem nerozeznatelnosti, ale zároveň předpokládá existenci množiny statistik, které tuto ekvivalenci definují a zároveň tím parametrizují prostor všech možných reálných textur.

Problémem této definice je zejména rozdíl v obecném výpočtu statistik na celém prostoru náhodného pole a lidském vnímání, které porovnává individuální obrazy mezi sebou. Zároveň také samotná nerozeznatelnost nemá přesnou definici a závisí na individuálním hodnocení či podmínkách pozorování. Samotné testování této hypotézy se také ukázalo velmi složité. Hodnocení na náhodném výběru dat je nespolehlivé a nepokrývá veškeré krajní případy. Lepší je tzv. syntéza analýzou, kdy se speciálně vybírají textury se stejnými statistikami, ty se uměle syntetizují a zkoumá se jejich podobnost. Pokud poté textura splňující podobnost statistik není vizuálně podobná, lze tvrdit, že dané statistiky nefungují. [15]

Touto problematikou a nalezením vhodných statistik se zabývali Portilla a Simoncelli v práci [15].

Celkové výhody použití takto syntetizovaných textur jsou popsány v práci [16]. Zejména v 3D prostoru je výhodou možnost přizpůsobit texturu potřebným podmínkám, velikosti povrchu, který je potřeba pokrýt, bez ostrých hran přechodů mezi dlaždicemi. Postup pomocí syntézy také zabírá méně místa, jelikož stačí uložit pouze pár parametrů pro syntézu místo samotných dat textury materiálu.

Dalším možným přístupem pro zachycení vizuálních charakteristik pomocí statistik je postup popsáný v práci [16], který je založený na kombinacích diskretních pravděpodobnostních rozdělání. Definuje černobílou texturu jako diskretní rozdělání hodnot pixelů ve stupních šedé. Dle vlastnosti homogenity textury jsou její vlastnosti statisticky závislé na marginální pravděpodobnosti hodnot pixelů menší části textury, která se opakuje. Tato opakující se část tedy obsahuje všechny informace potřebné pro samotnou syntézu textury. Tento postup se ukázal jako dobrý zejména pro textury se silnou periodicitou, opakujícími se vzory. Složitější je ale jeho použití pro barevné syntézy textur, kde je komplikovaná zejména časová náročnost či komplikovanější textury, kde produkuje pouze nicneříkající šum. [16]

Pravděpodobnostní modely lze použít i pro modelování materiálů reprezentovaných pomocí BTF (1.1.3.3). Modely jsou generativní, pro syntézu není tedy třeba žádné předchozí měření. Opět je zde tedy výhodou zmenšení potřebných dat, jelikož jsou ukládány pouze parametry modelu, není potřeba ukládat žádné měřené hodnoty pixelů. Některé tyto modely používají Markovovy náhodné pole nebo 3D CAR (3D causal auto-regressive texture model). Ty jsou poměrně rychlé, ale vyžadují analýzu a syntézu všech BTF snímků, což je ve výsledku výpočetně náročné. Model představený v [17] tak podobné pravděpodobnostní modely využívá pouze na menším podprostoru BTF snímků a výsledky kombinuje dohromady s pomocí dalších metod.

Výhodou pravděpodobnostních modelů je to, že závisí pouze na několika parametrech na rozdíl například od metod hlubokého učení (1.2.5), které vyžadují i desítky násobně více paramaterů např. konvoluční neuronové sítě potřebují okolo 50 tisíc parametrů oproti metodě představené v práci [15], která jich potřebuje okolo 1 tisíce. [18] Nevýhodou může být velká komprese informace, která se v některých případech odráží na kvalitě výsledku.

## 1.2.2 Metody lineární dekompozice

V těchto modelech je využita určitá reprezentace snímků (matice, 3D-tensor, 4D-tensor) a na ni je poté použita forma lineární dekompozice. Tím je rozložena informace o textuře ze všech snímků do několika částí, které je poté samostatně možno komprimovat nebo jinak upravovat. Výhodou je, že tyto části mají jasnou definici informace, kterou obsahují a je tak jasné, která informace je komprimována.

### 1.2.2.1 Metody využívající singulární rozklad

V práci [19] je zdůrazněna důležitost velkého množství snímků materiálu pořízených za různých podmínek světla a pohledu. Textury reálných materiálů jsou podle této práce příliš složité a nevyzpytatelné pro nějakou obecnou definici sady charakteristik, která by je parametrizovala. Zároveň představuje metodu, která pro samotnou syntézu textur potřebuje jen malý počet koeficientů textury a báze vektory.

Nejprve jsou snímky upraveny 2D-homografií. Tím se upraví perspektiva struktur v texturách tak, že jsou všechny na stejném místě, stejně velké a ve stejné rovině. Tím se hodnoty struktur dostanou v mapě pixelů na stejné místo a zbaví se hrubých geometrických rozdílů s tím, že si zachovávají stíny způsobené nerovnostmi a specifickými detaily textury. Poté je vytvořena matice průměrných hodnot pixelů přes všechny směry osvětlení a pohledu. Báze a koeficienty textury jsou pak nalezeny s využitím singulárního rozkladu (SVD) získané matice. Tyto koeficienty poté definují hodnoty pro jakoukoliv pozici světla a pohledu na daný pixel. [19]

Složitějším modelem využívající dekompozice je model „TensorTextures“ představený v práci [20]. Model místo matice a singulárního rozkladu využívá vícedimenzionálních tensorů a multi-

lineární algebry. Pomocí v práci definovaného singulárního rozkladu, který lze použít pro 4D-tensory, rozloží matici fotografií na 4 části. Tři části zakódovávají prostor informací o povrchu, směrech osvětlení a směru pohledu a čtvrtá část řídí jejich interakce. Pro výslednou reprezentaci jsou poté potřeba pouze 2 vektory koeficientů s celkovým počtem 58 koeficientů na reprezentaci charakteristik materiálu.

Výhodou tohoto postupu a použití složitější reprezentace je zejména možnost rozlišení, které hodnoty modelu odpovídají změně pozice světla, změně pozice pohledu a možnost komprese a úpravy jednotlivých informací zvlášť. Je tedy jasné, která informace se při kompresi ztratí. [20]

Navazujícím složitějším modelem je model představený v práci [21]. Zaměřuje se na větší odstranění redundance ve více-dimenzionální reprezentaci dat při současném zachování prostorové struktury. Přímo BTF data reprezentuje pomocí 4D-tensoru. Tento tensor je dále upraven dekompozicí pro zmenšení redundance a získá kompaktnější reprezentace. Míru zmenšení redundance oproti velikosti aproximační chyby při následné syntéze si navíc určuje sám uživatel. Tento přístup dle experimentů dosahuje nejmenší chyby při syntéze ze všech předchozích modelů za stejné dobré komprese co předchozí model. [21]

Tyto metody je sice možné použít pro realistickou syntézu textur, jsou ale výpočetně náročné a tedy pomalé pro jakýkoliv rychlejší rendering.

### 1.2.2.2 Metody využívající analýzu hlavních komponent

Méně výpočetně náročný přístup je představen v práci [22], která se zaměřuje na realistickou vizualizaci látky.

Hlavním principem tohoto modelu je pro zobrazení textury za požadovaných podmínek pozorování a světla vzít BTF snímek s podmínkami nejbližšími těm požadovaným. Jelikož je z praktického hlediska zejména kvůli velikosti souborů nemožné skladovat databázi veškerých snímků, je využita redukce pomocí analýzy hlavních komponent (PCA). Jelikož některé látky mají výrazné povrchové výškové nerovnosti (např. vystupující chlupy vlněného svetru), je PCA analýza provedena pro každý úhel pohledu zvlášť a zmenšení se týká tedy pouze vlastností, které způsobuje měnící se světlo. Experimentálně bylo v práci zjištěno, že stačí 16 hodnot nových snímků pro jeden úhel pohledu, což je oproti původním 81 snímkům výrazné zjednodušení.

Práce také upozorňuje na omezení syntetizovaných textur. Ty sice mohou být vytvořeny pro jakoukoliv délku a šířku, ale při syntéze se ztrácí informace o struktuře, která je pro některé materiály klíčová. Proto místo syntetizovaných textur využívá všechny snímky BTF modelu. [22] Stejnou výhodou velkého počtu různých snímků vyzdvihovala také práce [19].

Další možný přístup využívající lokální PCA analýzu je popsán v práci [23]. Základem je reprezentace BTF modelu dat jako množiny BRDF modelů a provedení PCA analýzy. Následně je představen algoritmus využívající clusterování a lokální výpočet PCA analýzy pro zmenšení rekonstrukční chyby. [23]

## 1.2.3 Odrazivostní modely pracující po pixelech

Metody, které se zaměřují na uchování informace o materiálu z hodnot jednotlivých pixelů.

### 1.2.3.1 Modely využívající texturové mapy

Metoda polynomiálních texturových map je představena v práci [24]. Jednoduché texturové mapy se používají například v počítačové grafice a umožňují jednoduše napodobit strukturu povrchu materiálu na plochém modelovaném objektu. Důležitým faktorem pro realistické zobrazení, který ale jednoduché mapy nedokážou zachytit, je změna osvětlení. Model umožňuje efektivní realistické zobrazení výškových rozdílů povrchu díky informacím o odrazu světla a stínech, které povrch sám vytváří.



Vstupními daty je množina fotografií s různými úhly osvětlení ale se stejným úhlem pohledu, což pomáhá i jednoduššímu zisku dat. Na druhou stranu se ztrácí informace o lesklosti povrchu, metoda se tak nehodí pro některé typy materiálů. Model zjednodušuje výpočet barevné informace pixelu na výpočet hodnoty luminance a vynásobení konstantní hodnotou pro jednotlivé barevné kanály. Výsledná reprezentace luminance pomocí koeficientů polynomu je fitována na data po texturových elementech a uložena jako polynomiální texturová mapa.

Nevýhodou toho modelu je to, že kvůli zjednodušení barevné informace způsobuje rozmazání ostrých hran stínů a celkový dojem změny bodového světla na prostorové. Výhodou je, že je oddělena informace o jednotlivých barevných kanálech a je tedy možné jednoduše ovlivňovat barvu textury. [24]

Model zaměřující se na rendering BTF dat v různých stupních detailů je představen v práci [25]. Model využívá rozklad pomocí Laplaceovské pyramidy a komprimaci dat pomocí PCA. Výsledek je transformován do reprezentace používající texturové mapy.

Výhodou tohoto modelu je právě práce s detailností. Zachovává přesnost hodnot pixelů v různých rozlišeních a pomáhá odstranění artefaktů a Moiré efektů pomocí plynulého přechodu od BTF dat zachycujících texturu povrchu k BRDF datům modelujícím hladký povrch. Zároveň umožňuje velkou kompresi dat a rendering v reálném čase. [25]

### 1.2.3.2 Modely využívající odrazivostní pole

Model, který aproximuje BTF data pomocí množiny odrazivostních polí (reflectance fields), je představen v práci [26]. Odrazivostní pole povrchu je definováno jako BTF model se zafixovaným úhlem odraženého světla, což prakticky znamená fixní úhel pohledu.

V modelu se využívá aproximace pomocí Lafortunových laloků, které na rozdíl od polynomiálních texturových map (1.2.3.1) zachovávají ostré stíny a vlastnosti odlesku pro různé úhly pohledu. Aproximace odrazivostních polí jsou poté uloženy jako 3D textury. Model při aproximaci pracuje pouze s hodnotami luminance, barva je získána vynásobením průměrnou hodnotou.

Model má tak výhodu komprese dat navíc s renderováním v reálném čase. Nehodí se ale pro velmi strukturované materiály jako noviny či obrazy a občas má problémy při výpočtech, které způsobují jednotlivé černé či bílé pixely v textuře. [26]

Navazující model také používající odrazivostní pole povrchu je představen v práci [27]. Je představena metoda aproximace používající pouze jeden Lafortunův lalok, čímž se výrazně sníží potřebný počet parametrů. Kvalita reprezentace je poté zlepšena pomocí funkce mapující hodnoty histogramů originálního a syntetizovaného obrázku. Model lépe zachovává barevnou informaci a výsledné syntetizované textury díky vyššímu kontrastu vypadají ostřejší.

### 1.2.3.3 Modely pracující nad SVBRDF daty

Model představený v práci [28] se zaměřuje na složitou strukturu dřeva. Podrobně definuje vlastnosti povrchu dřev, analyzuje odrazivost, která je závislá na podpovrchovém odrazu světla. Porovnává vlastnosti ošetřeného a neošetřeného povrchu dřeva. Práce využívá dva typy naměřených SVBRDF dat, která jsou po pixelech fitována na BRDF model, který dobře zachytí fyzikální strukturu dřeva. Model mapuje příchozí a odražený vektor světla na směr vláken pod povrchem dřeva. Důležitou součástí je vynechání oblastí s odleskem nebo naopak s příliš velkým stínem. Ty totiž ovlivňují předpokládanou osu podpovrchových vláken dřeva. [28]

Dalším modelem, který používá také SVBRDF data je model představený v práci [29]. Využívá postupné dekompozice SVBRDF dat až na 2-dimenzionální funkce, u izotropických materiálů až na 1-dimenzionální křivky. Pomocí postupných rozkladů vznikne stromová struktura, která reprezentuje materiál. Jednotlivé listy poté odpovídají různým fyzikálním vlastnostem materiálu jako je např. tvar odlesku či Fresnelovy efekty. Ty lze navíc libovolně upravovat a tím měnit povrchovou texturu, barvu, odrazivé vlastnosti, tvar odlesku apod. [29]

## 1.2.4 Přístupy k modelaci na základě vzoru

Modely využívající přímo vzorová naměřená data pro syntézu nových materiálů se stejnými vlastnostmi.

### 1.2.4.1 Modely využívající 3D textony

Model představený v [30] využívá k reprezentaci vlastností materiálu tzv. 3D textony. Jde o vzorové kousky materiálu, které reprezentují jeho lokální geometrii a odrazivé vlastnosti. Cílem práce bylo vytvořit soubor těchto 3D textonů a využít je pro zobrazení vlastností libovolného požadovaného materiálu. Dostatečně reprezentativní a zároveň kompaktní sady 3D textonů bylo dosaženo pomocí clusterování materiálů trénovací množiny. [30]

Práce [31] se soustředí na realistické zobrazení syntetizovaných BTF dat na libovolném povrchu pomocí prostoru tzv. povrchových textonů. Tyto povrchové textony ve formě povrchové textonové mapy zachovávají strukturu původních dat a chovají se správně i při změně podmínek okolí povrchu. Nevýhodou tohoto modelu je, že jej nelze použít na materiály, které nelze reprezentovat pomocí 3D textonů. [31]

### 1.2.4.2 Modely využívající skládání dlaždic

Model nazvaný „prošívání obrázků“ („image quilting“) je představen v práci [32]. Model lze použít jak na jednoduchou a rychlou syntézu textur, tak na rendering obrázku s jinou texturou než byla jeho původní. Zachová se tak tvar zobrazený na obrázku, ale je na něj zobrazena jiná textura.

Základem algoritmu modelu je náhodný výběr bloků původní textury a sestavení nové textury z nich. Pro lepší výsledky jsou vybírány bloky, které spolu na hranici souvisí a jsou do nového tvaru textury vkládány tak, že se překrývají. Ostré hrany mezi bloky jsou poté změněny na nelineární cestu okolím s nejmenší chybou.

Pro rendering obrázku s jinou texturou je navíc představeno omezení pomocí korespondenční mapy. Ta omezuje výběr bloků textury např. pomocí mapování hodnot luminance. Pro nejlepší výsledky je v práci představen iterativní postup pomocí zmenšování velikosti bloku původní textury, dokud nemají výsledky dostatečně malou chybu. [32]

Model, který navazuje na techniku prošívání obrázků, ale aplikuje ji na složitější strukturu BTF dat, je představen v práci [33]. Využívá kompresi informace o vzhledu při různém úhlu osvětlení pomocí sférických harmonických funkcí („spherical harmonics“).

Metoda nazvaná BTF válec („BTF roller“) je představena v práci [34]. Je založena na sestavení dlaždic do tvaru toroidu, což umožní opakování v horizontálním i vertikálním směru bez viditelné hranice. Výhodou je, že si poradí i s materiály s komplikovanou strukturou. Navíc syntéza poté probíhá rychle, jelikož kromě prvního sestavení toroidu není potřeba žádných dalších výpočtů. [34]

Součástí většiny představených modelů je hledání hranice mezi bloky textury tak, aby byla nerozpoznatelná. Právě efektivním hledáním nerozpoznatelné hranice mezi bloky textury se zabývá práce [35]. Představený algoritmus je suboptimální, ale jeho chyba není viditelná. Navíc je představeno řešení pro oblasti, kde neexistuje hranice s malou hodnotou chyby a vznikají tak nechtěné artefakty. V práci je představen i model využívající definovaný algoritmus pro syntézu materiálu pomocí spojování bloků původní textury. [35]

### 1.2.4.3 Modely využívající pro skládání Wangovy dlaždice

Složitějším způsobem výběru a skládání bloků textury jsou Wangovy dlaždice („Wang tiles“). Základním principem je výběr sady čtverců s okraji označenými určitou barvou. Čtverce jsou



následně k sobě skládány tak, že sousedící strany musí mít stejnou barvu bez otáčení či zrcadlení čtverců. Použití tohoto principu pro syntézu textur bylo již zkoumáno v několika pracích, příkladem může být práce [36].

Model představený v [37] využívá právě Wangovy dlaždice pro získání bloků BTF dat použitelných pro další syntézu. BTF data jsou nejprve zkomprimována pomocí sférických harmonických funkcí, v práci použita metoda komprese pomáhá i s odstraněním šumu. Následně jsou z dat zkonstruovány Wangovy dlaždice. Každá dlaždice má jinou kombinaci barevných okrajů, čímž je zaručena náhodnost ve výsledné textuře.

Model navíc umožňuje uživatelsky ovládané interaktivní úpravy dlaždic pomocí grafického rozhraní. To pomáhá například s přidáváním prvků textury (např. nerovnosti, pravidelné otvory), které by automatický systém mohl nesprávně ořezat či úplně vynechat. [37]

## 1.2.5 Metody hlubokého učení

Hluboké učení je v této době velmi populární metodou řešení problémů. Jedná se o kategorii strojového učení využívající neuronové sítě.

Celkovým komplexním popisem problémů v oblasti reprezentace materiálů a jejich řešení se pak zabývá práce [38]. Jedná se o popis vývoje za posledních několik desetiletí a cituje přes 250 důležitých publikací. Konkrétně popisem modelů hlubokého učení se zabývá práce [39]. Problémy se zabývá jak z hlediska grafiky, tak z hlediska strojového učení.

### 1.2.5.1 Modely umožňující syntézu vzhledu

Práce [40] představila reprezentaci pomocí neuronové sítě nazvané DAM („Deep Appearance Maps“). Síť se naučí na vzorových obrázcích či snímcích videa homogenního materiálu se známými úhly pohledu a orientace povrchu. Následně umožňuje syntézu vzhledu materiálu pro zadané úhly pohledu a orientace povrchu. Dalším využitím, které je v práci představeno, je systém pro segmentaci materiálů z obrázku, který určitý počet materiálů namapuje na reprezentace pomocí DAM. [40]

Další model představený v práci [41] se zaměřuje na problém realistické úpravy vzhledu materiálu na základě jednoho vzorového obrázku. Model využívá generativních neuronových sítí pro zachycení vysokoúrovňových vlastností materiálu. Pomocí jejich úpravy je poté možné ovlivnit vnímání vlastností materiálu člověkem. Práce se zaměřuje konkrétně na vlastnosti metalicity a lesklost. [41]

### 1.2.5.2 Modely pracující nad SVBRDF daty

Model zabývající se fyzicky přesným modelováním SVBRDF dat z jednoho obrázku materiálu je představen v práci [42]. Model pro učení a modelaci využívá konvolučních neuronových sítí. V práci je navíc představena iterativní metoda na získání dostatečného množství dat pro trénování.

Model představený v práci [43] zjednodušuje složitý získání SVBRDF dat na pouhé zakódování a dekodování informací. Autoenkodér nejprve zakóduje vzorové chování světla na povrchu materiálu a poté ho dekoduje na samotná SVBRDF data. Celkově tak zjednodušuje získání SVBRDF dat, která by jinak potřebovala tisíce až miliony snímků pro reprezentaci jednoho materiálu. [43]

Model kombinující přístup obou předchozích je představený v práci [44]. Soustředí se také na získání SVBRDF dat z jediného obrázku a využívá k tomu princip autoenkodéru. Výsledný model získá informace o materiálu z jediného obrázku osvětleného drženým světlem. Zároveň je definována metrika, která porovnává renderované obrázky reálných a syntetizovaných dat. To pomáhá s učením vlastností, které jsou závislé na pohledu a nemohou tak být rozpoznány na jednom obrázku. [44]

Navazujícím modelem pracujícím se SVBRDF daty je model představený v práci [45]. Jeho výhodou oproti předchozím dvěma modelům je možnost na vstup vložit libovolné množství ob-

rázků s tím, že podporuje i vysoká rozlišení. Model sám optimalizuje parametry vzhledu a není potřeba žádná heuristika navíc pro regularizaci optimalizace. [45]

Trochu jiný přístup pro práci se SVBRDF daty využívá model představený v práci [46]. Základem je generativní adversiální síť neboli GAN, což je generativní model postavený na principu soupeření dvou neuronových sítí. Model se z fyzicky měřených či syntetických vzorků učí vysokofrekvenční směrové vzory na povrchu materiálu. Navíc je představena optimalizace syntézy SVBRDF dat, kdy je počítána pouze ta část výpočtu, která daný bod v daném směru ovlivňuje. Další výhodou modelu je syntéza velké plochy textury ve velkém měřítku bez opakujících se prvků. [46]

### 1.2.5.3 Modely pro rozpoznávání materiálů

Model nazvaný „DeepTEN“ je představen v práci [47]. Model představuje neuronovou síť s přidanou kódovací vrstvou, která celý proces učení a kódování informací provede v jednom procesu trénování sítě. Veškeré navazující části je navíc možné vzájemně optimalizovat. Model je následně použit pro efektivní rozpoznávání materiálů a textur. Jeho další výhodou kromě kompaktnosti je možnost učení na více datasetech s různými velikostmi a označením tříd materiálů. [47]

Dalším modelem zabývajícím se rozpoznáváním materiálů je model představený v práci [48]. Jeho výhodou je využití pravděpodobnostní klasifikace a kombinace učení několika znalostních klasifikátorů v ensemble přístupu, díky čemuž dosahuje mnohem lepších výsledků než předchozí modely. [48]

### 1.2.5.4 Modely pracující nad BTF daty

Model představený v práci [49] se soustředí na naučení neuronové sítě pro reprezentaci BTF dat a následnou predikci nových snímků při jiných směrech osvětlení a pohledu. Pro trénování byla použita data o směru osvětlení, pohledu a typu materiálu. Pro hodnocení výsledků byla poté použita metoda SSIM („structural similarity“) a porovnání s modelem CVAE („Conditional Variational Auto Encoder“). [49]

Model představený v práci [50] se soustředí zejména na komprimovanou reprezentaci BTF dat pomocí neuronové sítě. Pracuje na principu autoenkodéru, který komprimuje snímky s různým úhlem osvětlení a pohledu přes jednotlivé elementy textury a následně pro zadané parametry osvětlení a pohledu vrátí vektor RGB hodnot. Výhodou je dobrá komprese a navíc možnost syntézy libovolného směru osvětlení a pohledu, což eliminuje potřebu interpolace mezi původními snímky BTF dat, které mají směry omezené. Nevýhodou je potřeba trénování modelu pro každý nový materiál zvlášť. [50]

Na komprimaci BTF dat se také zaměřuje model představený v práci [51]. Jeho principem je syntéza materiálu pod různými azimuty pozice světla z jediného snímku textury. Využívá konvoluční neuronové síť U-Net, která při učení zachovává lokální vlastnosti textury. Výhodou je kromě komprimace informací navíc i urychlení procesu měření dat, jelikož stačí změřit snímek pouze pro jeden azimut světla. Kvalita výsledků je opět měřena pomocí metody SSIM. Nevýhodou je, že ze zkoumaných kategorií model podává dobré výsledky pouze pro textury dřeva a látky. [51]

Práci zabývající se kódováním BTF dat je práce [52]. Model se snaží zachytit chování odrazivostních funkcí materiálů a zakódovat je do vektoru parametrů v latentním prostoru. Trénování probíhá na libovolně velké množině BTF dat a zároveň se soustředí i na rozmanitost materiálů. Model pak charakterizuje materiály do jediného prostoru parametrů a na rozdíl od modelu [50] tak není potřeba trénovat pro každý materiál zvlášť. [52]

## 1.3 Lidské vnímání materiálů

Principem lidského vnímání materiálů se zabývalo v minulosti mnoho prací. Jedná se o problémy jako:

- pomocí jakých vlastností lze charakterizovat chování materiálu
- do jakých skupin na základě vlastností je možné materiály kategorizovat
- jak ke kvalitě lidského vnímání přispívá kvalita informace, barva, tvar objektu či zvuková informace
- hledání prostoru všech materiálů s dimenzemi podle vlastností vnímaných člověkem
- hledání obecného systému, který by lidské vnímání charakterizoval

Celkový přehled tohoto výzkumu poskytuje práce [53].

Výzkum vnímání materiálu se postupně rozdělil na dva hlavní proudy. Jeden charakterizuje vzhled materiálu pomocí množiny statistických měření. Lidský mozek dle tohoto principu nezajímají fyzické vlastnosti materiálu, ale namísto toho si vytváří a přizpůsobuje vlastní generativní statistické modely. [54] Druhý proud zkoumá výrazné vlastnosti, rysy materiálu, často nazývané „textony“. Charakterizace materiálu je poté provedena pomocí kombinace vlastností z textonového slovníku. Oba přístupy jsou zmíněny a poté více rozebrány v [53], kde je shrnut i jejich historický vývoj.

### 1.3.1 Vnímání materiálů ve formě fotografií

#### 1.3.1.1 Charakterizace pomocí statistik

V práci [55] je představen přístup charakterizace materiálu pomocí 6 základních vlastností – *hrubost* („coarseness“), *kontrast*, *směrnost*, *tvar prvků textury* („line-likeness“), *pravidelnost*, *drsnost* („roughness“).

Hrubost odkazuje k velikosti prvků textury, často je vztahována k měřítku. Jedná se např. o velikost mezer mezi vlákny látky nebo velikost oblázků kamenného povrchu. Drsnost se vztahuje k výškové změně povrchu např. drsný povrch dřeva oproti hladkému povrchu dřeva vyleštěného. Tvar prvků textury charakterizuje, zda jsou prvky textury spíše podobné liniím nebo jsou kulovitého tvaru.

Tyto vlastnosti byly hodnoceny lidmi na 16 reprezentativních vzorcích z Brodatzova katalogu [56] v digitální formě. Lidské hodnocení vlastností bylo porovnáno s uměle vypočítanými hodnotami. Dobré výsledky byly zaznamenány pro hodnocení pomocí *hrubosti*, *kontrastu* a *směrnosti*. [55]

Práce [57] rozšiřuje charakterizaci lidského vnímání a kategorizace materiálů na 12 vlastností – *hrubost*, *kontrast*, *směrnost*, *pravidelnost*, *drsnost*, *repetitivnost*, *granularita*, *náhodnost*, *hustota prvků*, *strukturální složitost* a *orientace*. Hodnocení vlastností opět probíhalo na vzorcích z Brodatzova katalogu [56]. Experiment kromě hodnocení obsahoval i seskupování vzorků do libovolného množství skupin.

Na výsledky hodnocení vlastností byla použita klasifikační a regresní analýza pomocí CART stromů, diskriminační analýza a PCA analýza. Na výsledky seskupování vzorků poté hierarchická clusterová analýza a neparametrické vícedimenzionální škálování.

Výsledkem klasifikace bylo 8 skupin materiálů, dobře pojmenovatelnými byly materiály *zrnité*, *mramorované*, *krajkovité*, *nestruturované* a *směrové*. Celkovým výsledkem experimentů je poté prostor charakterizující textury o 3 dimenzích měřících *repetitivnost*, *současně kontrast* a *směrnost* a *současně zrnitost*, *hrubost* a *komplexitu*. [57]

Podobný experiment se seskupováním materiálů byl proveden v práci [58]. Hlavní zjištěné vlastnosti skupin materiálů jsou *komplexnost, propojenost, hloubka, tvrdost, linearita, přirozenost, orientace, opakovatelnost, drsnost, tvar, velikost a struktura*. Experiment byl proveden celkem třikrát pro potvrzení výsledků. Práce popisuje rozsáhlou analýzu použitých postupů v experimentech. [58]

Práce [59] posunula problematiku dále v tom, že v experimentech uvažovala barevné snímky materiálu, bylo tedy potřeba zařadit i charakteristiky týkající se barvy. Experiment se více zaměřoval na podobnost barev a vzorů materiálu. Lidé hodnotili podobnost materiálů v kategoriích – *celková barva, směrovost a orientace, pravidelnost a umístění vzoru, čistota barvy, komplexita a těžkost*.

Z výsledku experimentu poté pomocí více-dimenzionálního škálování vznikl slovník vzorů materiálů. K samotnému slovníku poté pomocí hierarchického clusterování dat experimentu vznikla gramatická pravidla.

Práce navazuje na výsledky práce [57], která pracovala pouze s černobílými obrázky. Některé vlastnosti jsou zachovány, je však upozorňováno, že jejich význam a způsob posuzování se s přidáním barev lehce mění (např. pravidelnost již není jen o pravidelnosti intenzity, ale i o tom, zda je pravidelný barevný vzor). Je také upozorňováno na důležitost významu vzorů (např. porovnávání materiálu květin a květinového vzoru látky). [59]

Vztahem klasifikace materiálů a posuzování jejich vlastností ve vizuální i sémantické rovině se zabývá práce [60].

V jednom experimentu lidé hodnotili obrázky několika skupin materiálů pomocí těchto vlastností – *lesklost, průhlednost, barevnost, drsnost, tvrdost, studenost, křehkost, přirozenost, půvabnost*. Ve druhém poté lidé dostali název skupiny materiálů a tu následně označili pomocí některých ze 42 přídavných jmen.

Bylo zjištěno, že dané vlastnosti dobře popisují jednotlivé skupiny. Na základě hodnot hodnocení nebo popisu skupiny pomocí vlastností lze s velkou pravděpodobností správně určit danou materiálovou skupinu. Vlastnosti tak umožňují skupiny v prostoru odlišit. Hlavním zjištěním poté byla podobnost relativního umístění skupin v prostorech z obou experimentů. To implikuje spojení vizuálních a paměťových informací při rozpoznávání materiálů. [60]

Navazující práci pracující se stejnými hodnotícími vlastnostmi ale s postupnou degradací informace o materiálu, je práce [61]. Experiment začíná s fyzickými exempláři materiálů a jejich fotografiemi ve stejném prostředí. Následně jsou použity datasety s různými kombinacemi degradace informace o barvě a rozlišení. Dataset materiálů byl sestaven tak, aby experiment nebyl ovlivněn tvary materiálu a hodně saturovanými barvami.

S postupnou ubývající informací o materiálu se hodnocení účastníků čím dál více lišila a celkově se kvalita vnímání snižovala. Největší kvalitativní skok byl při ztrátě barevné informace. Pouze vnímání vlastností *tvrdost a studenost* se zlepšilo u dat s nízkým rozlišením. [61]

### 1.3.1.2 Charakterizace pomocí textonů

Parametrickým popisem obrázků pomocí textonových vlastností se zabývá práce [62]. Je definován parametrický prostor textur, kde parametry odpovídají textonovým vlastnostem.

Pro zmenšení dimenze tohoto prostoru je poté použito více-dimenzionálního škálování. To umožňuje takovou reprezentaci prostoru, kde body odpovídají jednotlivým texturám a vzdálenosti mezi body odpovídají rozdílům mezi texturami.

Výhodou modelu je možnost využití pro reprezentaci libovolné textury její blízkost k vybraným texturám prostoru a poté i možnost syntézy textur na základě nastavení parametrů prostoru. [62]

Práci zkoumající vlastnosti materiálu na úrovni jednotlivých pixelů je práce [63]. Snaží se modelování oprostít od informací získaných z tvaru objektu a scény obrázku.

Vlastnosti jsou modelovány pomocí vizuálních rysů materiálu („visual material traits“). Samotným modelem jsou poté konvoluční jádra učící se při nesupervizovaném učení rozpoznávat

tyto materiálové rysy na úrovni pixelů. Tento způsob umožňuje lokální učení vlastností bez zakódování informace o hranici objektu. Výhodou modelu je schopnost segmentace objektů z obrázků i generalizace na nové datasey materiálů. Samotné vizuální rysy materiálů pak pomáhají k rozpoznávání skupin materiálů. [63]

Navazující prací je poté práce [64] vydaná o 2 roky později. Ta se soustředí na nalezení celého prostoru lokálně rozeznatelných vlastností podle vizuálních vzdáleností materiálů.

Navazujícím modelem je model představený v práci [65], která se soustředí na kategorizaci materiálu z jediného snímku. Modelem je SVM klasifikátor, který využívá sadu nízko-úrovňových a středně-úrovňových vlastností, které jsou založeny na lidském rozpoznávání materiálů.

Model byl evaluován na materiálové databázi Flickr (FMD), která představuje velké množství materiálů a tedy obtížnou úlohu pro rozpoznávání. Úspěšnost modelu za běžných podmínek je asi o 30% horší než lidské hodnocení. Pokud se ale evaluace zaměří na lokální vlastnosti, je jejich hodnocení srovnatelné. [65]

### 1.3.2 Vnímání materiálu ve formě objektů

Vlastnosti materiálu reprezentované pomocí BTF dat jsou závislé na úhlu pohledu a úhlu světla. Veškeré vlastnosti materiálu jsou tak nejlépe prozkoumány na objektu, který reprezentuje co největší část úhlů pohledu a osvětlení.

Redukcí BTF dat při současném zachování dostatečného množství informace na základě lidského vnímání vlastností materiálu se zabývá práce [66]. V experimentech bylo zjištěno, že redukce závisí na typu materiálu, komplexnosti osvětlení a geometrii objektu. Na základě výsledků byla vytvořena metrika komprese BTF dat s uživatelsky nastavitelnou vizuální kvalitou komprese. Tato komprimovaná data navíc dosahují lepších výsledků při dalším kompresním procesu pomocí PCA analýzy.

Další prací zabývající se kompresí informace v BTF datech je práce [67]. Soustředí se na aproximované více-dimenzionální filtrování a jeho vliv na vizuální kvalitu zobrazení materiálu. Pro pohybující se světlo i kameru se filtrování týká dimenzí světla, úhlu a času. Studie také porovnávala efekty filtrování pro statické a dynamické scény. Statické obrázky preferují vysoký kontrast v prostorové dimenzi, dynamické je naopak žádoucí více filtrovat, jelikož pak nevznikají nepříjemné artefakty typu aliasingu.

Výsledky filtrování byly poté ohodnoceny pomocí psychofyzikálních experimentů nejprve na jednoduchém osvětlení a geometrii, poté na složitějších modelech se složitějším sestavením světla. [67] Při testování byla využita metoda vizuální ekvivalence definovaná a více prozkoumaná v práci [68].

Práce [69] přidává analýzu kromě vizuální i zvukové informace materiálu. Zvukovou informaci zde představují nahrávky různého způsobu kontaktu prstu s povrchem materiálu.

První experiment zkoumal vztah a využití různých kombinací vizuální a zvukové informace pro rozpoznávání vlastností. Hodnocení vlastností bylo rozděleno na 3 kategorie vlastností – *hmatové* (tvrdost, drsnost, teplota), *vizuální* (zářivost, složitost, barevnost) a *subjektivní* (cena, stáří, přírodnost, krása). Bylo zjištěno, že zvukový záznam pomáhá rozpoznat zejména materiálové vlastnosti vnímané hmatem.

Druhý experiment zkoumal zda je možné zmanipulovat vnímání vlastností výměnou zvukové informace. Výsledky ukazují, že lze takto konzistentně měnit vnímání materiálu zejména u hmatových vlastností. [69]

## 1.4 Návaznost na předchozí práce

Co se týče důležitých studií, na které navazuje tato práce, jedná se zejména o práci [55], ve které se poprvé začal zkoumat vztah vnímání materiálů a jejich výpočetních statistik. Dále práce [59], která pokračuje se zkoumáním vnímání u barevných vzorků a práce [61], která řeší vnímání

dat při zmenšujícím se množstvím informace. Stejně jako tato práce i všechny tyto předchozí zkoumají vztah vizuálních a výpočetních statistik. Snaží se najít systém, ve kterém by pomocí výpočetních statistik zjištěných z dat materiálu bylo možné předpovědět hodnoty jeho vizuálních statistik. Tedy aby pomocí měření materiálu bylo možné předpovědět jeho vlastnosti vnímané člověkem. Tato práce na předchozí navazuje v hledání vhodných měřitelných statistik. Novinkou je zejména využití dynamických vzorků (videa) při lidském hodnocení. Vliv dynamických oproti statickým vzorkům bude dále více zkoumán i v dalším výzkumu.

Samotný výběr statistik byl inspirován prací [15]. Statistika *směrovost* byla poté převzata z prací [70, 71]

Práce navíc kromě nalezení vhodných statistik představuje praktické využití ve formě komprese BTF dat na základě nalezených statistik. Co se týče práce s BTF daty a komprese informace, tato práce souvisí s výzkumem v [66]. Obě práce využívají jako jednu z metod pro redukci BTF dat podobnost LAB kanálů snímků. V této práci je navíc představena metoda redukce BTF dat na základě podobnosti měřených statistik.

Co se týče budoucího využití pro nahrazení člověka při identifikaci materiálů či objektů lze navázat např. na výzkum [72], který konkrétně porovnává reálné materiály a jejich BTF reprezentace.

## Teoretické zázemí

*Tato kapitola je určena pro teoretické zázemí celé práce. Na začátek definuje výpočetní statistiky. Dále přiblíží použité metody analýzy dat v datasetu. Zavede teorii pro použité modely strojového učení a vyhodnocování jejich výsledků. Dotkne se použitých barevných prostorů a definuje metriky používané k vyhodnocování vzdálenosti snímků. Nakonec definuje sledované statistiky použité k ohodnocení kvality redukce dat.*

### 2.1 Definice výpočetních statistik

#### 2.1.1 Maximum

Maximální hodnota kanálu luminance obrázku materiálu.

Množinu všech hodnot luminance přes všechny pixely obrázku ozn.  $L$ . Potom je maximum z těchto hodnot definováno jako:

$$l_{max} \in L$$

takové, že

$$\forall l \in L : l_{max} \geq l$$

Pro výpočet hodnoty v Pythonu byla využita funkce knihovny Numpy – `numpy.amax` [73].

#### 2.1.2 Minimum

Minimální hodnota kanálu luminance obrázku materiálu.

Množinu všech hodnot luminance přes všechny pixely obrázku ozn.  $L$ . Potom je minimum z těchto hodnot definováno jako:

$$l_{min} \in L$$

takové, že

$$\forall l \in L : l_{min} \leq l$$

Pro výpočet hodnoty v Pythonu byla využita funkce knihovny Numpy – `numpy.amin` [73].



### 2.1.3 Průměr

Průměrná hodnota kanálu luminance obrázku materiálu. Pro výpočet je použit aritmetický průměr z hodnot. Představuje aproximaci střední hodnoty hodnot luminance za daných podmínek pro daný materiál.

Množinu všech hodnot luminance přes všechny pixely obrázku ozn. jako  $L$ , její velikost poté jako  $N$ . Průměr přes všechna  $l \in L$  je definován jako:

$$\bar{l} = \frac{\sum_{i=1}^N l_i}{N}$$

Pro výpočet hodnoty v Pythonu byla využita funkce knihovny Numpy – `numpy.mean` [73].

### 2.1.4 Rozptyl

Rozptyl hodnot kanálu luminance obrázku materiálu. Jedná se o druhý centrální moment náhodné veličiny. Označuje očekávanou střední hodnotu kvadrátů odchylek od střední hodnoty. Pro výpočet je použit odhad rozptylu získaný metodou maximální věrohodnosti. Nejedná se tedy o nestranný odhad ale o maximálně věrohodný odhad pro normálně rozdělené veličiny.

Množinu všech hodnot luminance přes všechny pixely obrázku ozn. jako  $L$ , její velikost poté jako  $N$ . Rozptyl přes všechna  $l \in L$  je definován jako:

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (l_i - \bar{l})^2,$$

kde  $\bar{l}$  je průměr získaný stejným způsobem jako v předchozím bodě (2.1.3).

Pro výpočet hodnoty v Pythonu byla využita funkce knihovny Numpy – `numpy.var` [73] s původním nastavením parametru `ddof`, tedy s hodnotou 0. Tím získáme variantu vzorce maximálně věrohodného odhadu.

### 2.1.5 Šikmost (Skewness)

Šikmost hodnot kanálu luminance obrázku materiálu. Jedná se o třetí standardizovaný moment náhodné veličiny. Označuje míru asymetrie. Může být buď kladná, nebo záporná podle toho, na kterou stranu se více odchyluje hustota pravděpodobnosti od střední hodnoty.

Množinu všech hodnot luminance přes všechny pixely obrázku ozn. jako  $L$ , její velikost poté jako  $N$ . Pro výpočet šikmosti přes všechna  $l \in L$  je použit Fisher-Pearsonův koeficient šikmosti definovaný jako:

$$g_1 = \frac{m_3}{m_2^{3/2}},$$

kde

$$m_i = \frac{1}{N} \sum_{i=1}^N (l_i - \bar{l})^i,$$

kde  $\bar{l}$  je průměr získaný stejným způsobem jako v definici statistiky průměru (2.1.3).

Pro výpočet hodnoty v Pythonu byla využita funkce knihovny Scipy – `scipy.stats.skew` [74].



## 2.1.6 Špičatost (Kurtosis)

Špičatost hodnot kanálu luminance obrázku materiálu. Jedná se o čtvrtý standardizovaný moment náhodné veličiny. Porovnává tvar hustoty pravděpodobnosti s normálním neboli Gaussovým rozdělením, které má hodnotu špičatosti 0. Kladná hodnota značí, že křivka hustoty je špičatější než u normálního rozdělení a většina hodnot leží blízko střední hodnoty. Záporná hodnota značí, že křivka hustoty je plošší než u normálního rozdělení a rozdělení hodnot je tedy rovnoměrnější.

Je potřeba korekce vychýlení odhadu, aby normální rozdělení mělo skutečně hodnotu 0. Je tedy použit Fisherův vzorec, kde je od odhadu odečtena hodnota 3. Špičatost je tedy definována jako:

$$g_2 = \frac{m_4}{m_2^2} - 3 ,$$

kde

$$m_i = \frac{1}{N} \sum_{i=1}^N (l_i - \bar{l})^i ,$$

kde  $\bar{l}$  je průměr získaný stejným způsobem jako v definici statistiky průměru (2.1.3).

Pro výpočet hodnoty v Pythonu byla využita funkce knihovny Scipy – `scipy.stats.kurtosis` [74].

## 2.1.7 Nízké, střední a vysoké frekvence

Informace o povrchu materiálu byly získány pomocí frekvenční výkonové spektrální hustoty („Power Spectral Density“ – PSD), která je definována jako síla prvků, neboli jejich celkový rozptyl, v různých rozlišeních určitého snímku. Čím vyšší hodnota výkonové spektrální hustoty, tím větší rozptyl prvků v daném rozlišení a tím silnější amplituda frekvenčního signálu.


Samotný zisk frekvenční výkonové spektrální hustoty je proveden pomocí Fourierovy transformace. Ta rozkládá obrázek jako dvourozměrnou funkci na součet harmonických složek – funkcí sinus a cosinus. Jednotlivé složky součtu mají postupně se zmenšující periody korespondující s postupně se zvyšujícím rozlišením. Amplitudy frekvenčního signálu složek s určitou periodou poté reprezentují rozptyl prvků určitého rozlišení snímku.

Obecně lze tuto dekompozici na harmonické složky provádět pro nekonečné množství rozlišení a tedy period. Tento postup se podobá například aproximaci funkce pomocí Taylorova rozvoje, kdy každý další člen součtu zpřesňuje aproximaci funkce. Zde je ale reálné omezení velikosti obrázku, kdy na jedné straně je rozlišení velikosti 1x1 (reprezentující průměr) a na druhé straně rozlišení původního obrázku, kdy jedna perioda zaznamená přesně jeden pixel. Jakýkoliv další prvek do součtu s menší periodou již nezaznamená žádnou další informaci, jelikož už vyšší rozlišení a tedy další informace neexistuje.

U vícerozměrné dekompozice, jako např. dvourozměrného obrázku, jsou určité kombinace rozlišení jednotlivých rozměrů, které dohromady reprezentují stejné celkové rozlišení. Je to možné vidět při zobrazení amplitudového spektra jako dvourozměrné heatmapy (Obr. 2.1), kde jsou stejné jakékoliv dvě poloviny s hranicí procházející středem. Tyto hodnoty reprezentující stejné rozlišení jsou seskupeny dohromady do „binů“, v nichž je spočítána průměrná hodnota amplitudy složek. Ta je následně vynásobena velikostí dat v daném binu pro získání celkové hodnoty. [75]


Výpočet probíhal na snímku o rozlišení 256x256 pixelů. Jedná se o mocninu dvojky, rozlišení lze poté jednoduše dělit dvěma pro získání dílčích menších rozlišení.

Pro zjednodušení získané informace o frekvencích z celého spektra jsou hodnoty rozděleny na 3 části – *nízké*, *střední* a *vysoké*. Výsledkem je průměrná hodnota přes všechny hodnoty v daném intervalu. Prahy intervalů period byly uměle nastaveny 0-4 pro nízké frekvence, 5-59 pro střední



■ **Obrázek 2.1** Amplitudové spektrum Fourierovy transformace snímku.

frekvence a 50-127 pro vysoké frekvence. Příklad grafu frekvenční výkonové spektrální hustoty je na Obr. 2.2.



■ **Obrázek 2.2** Frekvenční výkonová spektrální hustota a průměrné hodnoty frekvencí materiálu 1.


Postup pro výpočet frekvenční výkonové spektrální hustoty v jazyce Python byl převzat ze zdroje [75].

### 2.1.8 Směrnost


Výpočet směrnosti materiálu vychází z frekvenční analýzy snímku pomocí Fourierovy transformace podrobněji popsané v části věnující se frekvencím (2.1.7). Pro výpočet směrnosti je použita reprezentace amplitudového spektra ve formě dvourozměrné heatmapy. Jelikož jsou hodnoty v grafu stejné pro každou polovinu rozdělenou hranicí přes střed, je uvažována pouze polovina hodnot. Navíc jelikož bude graf rozdělován na jednotlivé kruhové výseče, je polovina oříznuta do tvaru půlkruhu, aby nadbytečné hodnoty nezkreslovaly výpočet (Obr. 2.3)

Heatmapa je rozdělena pomocí úseček na určitý počet kruhových výsečí reprezentujících různé části snímku. Výseče jsou následně rozděleny několika kružnicemi s různým poloměrem, ty reprezentují rozdělení frekvencí od nejnižších po nejvyšší postupně od středu. Čím více výsečí a kruž-

nic, tím bude směrovost přesnější. V každé takto vzniklé oblasti je vypočítána průměrná hodnota amplitud vynásobená velikostí oblasti. Tím vznikne nová dvourozměrná heatmapa s osami reprezentujícími výšece a kružnice a intenzita heatmapy označuje průměrnou hodnotu v dané oblasti. Takto vzniklý graf se nazývá „Discrete Fourier Polar Coordinates Matrix“ (DFPCM) (Obr. 2.4). [70]



■ **Obrázek 2.3** Postup Fourierovy transformace a ořezu hodnot do půlkruhu.



■ **Obrázek 2.4** Matice DFPCM zobrazující hodnoty amplitud v jednotlivých sektorech.

Pro samotný výpočet hodnoty směrovosti jsou využity jednotlivé součty hodnot ve sloupcích. Nejprve je nalezena maximální hodnota ze všech součtů ozn.  $f_{max}$  a poté je spočítána samotná směrovost podle vzorce:

$$D = \frac{\sum_{i=1}^N (f_{max} - f(i))}{N \times f_{max}},$$

kde  $N$  je počet sloupců a suma v čitateli probíhá přes všechny sloupce. [70, 71]

Směrovost označuje pouze míru orientace, jak moc je povrch materiálu směřovaný. Hodnoty v DFPCM by kromě výpočtu samotné směrovosti mohly být dále využity pro výpočet, do kterých

konkrétních směrů je materiál nejvíce orientován, tato skutečnost ale v práci využita není.

### 2.1.9 Barevnost (Chroma)

Průměrná hodnota kanálu chroma obrázku materiálu. Pro výpočet je použit aritmetický průměr z hodnot. Představuje aproximaci střední hodnoty hodnot chromy za daných podmínek pro daný materiál.

Množinu všech hodnot chromy přes všechny pixely obrázku ozn. jako  $C$ , její velikost poté jako  $M$ . Průměr přes všechna  $c \in C$  je definován jako:

$$\bar{c} = \frac{\sum_{i=1}^M c_i}{M}$$

Pro výpočet hodnoty v Pythonu byla využita funkce knihovny Numpy – `numpy.mean` [73]

## 2.2 Použité metody zjištění informací o datasetu

### 2.2.1 Korelace

Korelační koeficient popisuje vzájemné lineární závislosti veličin  $X$  a  $Y$ . Je definován pomocí kovariance  $\text{cov}$  a rozptylu  $\text{var}$ , které jsou definovány takto:

$$\text{cov}(X, Y) = E[(X - EX)(Y - EY)]$$

$$\text{var}X = E(X^2) - (EX)^2 ,$$

kde  $E$  značí střední hodnotu veličiny.

Pro získání korelace na konkrétních datech se místo výpočtu pomocí střední hodnoty využívá odhad rozptylu pomocí výběrového rozptylu a odhad kovariance pomocí výběrové kovariance – Pearsonův korelační koeficient. Pro výběr z náhodných veličin  $X$  a  $Y$  velikosti  $N$ :

$$\text{cov}(X, Y) = \sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})$$

$$\text{var}X = \sum_{i=1}^N (x_i - \bar{x})^2 ,$$

kde  $\bar{x}$  je výběrový průměr.

Korelace se poté spočítá:

$$\rho(X, Y) = \frac{\text{cov}(X, Y)}{\sigma_X \sigma_Y} = \frac{\text{cov}(X, Y)}{\sqrt{\text{var} X} \sqrt{\text{var} Y}}$$

Pro kompaktní vyjádření korelace všech příznaků je spočítána korelační matice, která je symetrická a na indexu  $ij$  (a tedy i  $ji$ ) má korelaci příznaků  $X_i$  a  $X_j$ . [76]

Pokud by příznaky byly příliš korelované a tedy lineárně závislé, mohlo by to uškodit při použití v lineární regresi. Poté je lepší jeden ze závislých příznaků vynechat.

Pro výpočet korelace v Pythonu byla využita funkce knihovny Numpy – `numpy.corrcoef` [77]

## 2.2.2 Analýza hlavních komponent (PCA)

Analýza hlavních komponent („principal component analysis“) je způsob redukce dimenzionality v datech s co nejmenší ztrátou informace. Jedná se o hledání takové ortogonální projekce bodů datasetu na podprostor s menší dimenzí, která minimalizuje kvadratickou chybu projekce. Prakticky pak minimalizace této kvadratické chyby znamená maximalizaci odhadu rozptylu projektovaných bodů.

Mějme dataset  $X \in \mathbb{R}^{N,p}$ , který obsahuje  $N$  bodů o  $p$  příznacích. Nejprve je potřeba provést středování datasetu. To je provedeno tak, že od každého bodu datasetu  $X$  je odečten výběrový průměr přes všechny body datasetu  $X$ . Vznikne tak nový vystředovaný dataset  $X'$ :

$$x'_i = x_i - \bar{x},$$

kde

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i$$

Pro ortogonální rozklad bodu  $x \in \mathbb{R}^p$  a jeho ortogonální projekci na prostor  $\mathbb{R}^q$  platí následující. Je-li  $b_1, \dots, b_p$  ortonormální báze prostoru  $\mathbb{R}^p$  takový, že prvních  $q$  vektorů  $b_1, \dots, b_q$  tvoří bázi podprostoru  $\mathcal{V}$  a zbylé vektory  $b_{q+1}, \dots, b_p$  jsou kolmé na  $\mathcal{V}$ , lze každý bod rozložit do součtu:

$$x = v_x + u_x,$$

kde

$$\begin{aligned} v_x &= \tau_1 b_1 + \dots + \tau_q b_q \\ u_x &= \tau_{q+1} b_{q+1} + \dots + \tau_p b_p \end{aligned}$$

Samotnou projekci části  $v_x$  na podprostor  $\mathcal{V}$  lze pak jednoznačně reprezentovat  $q$  rozměrným vektorem koeficientů:

$$t_x = (\tau_1, \dots, \tau_q)^T \in \mathbb{R}^q$$

Maticově lze vektor koeficientů zapsat jako:

$$t_x = V^T x,$$

kde  $V \in \mathbb{R}^{p,q}$  je matice, v jejíž sloupcích jsou zapsané vektory  $b_1, \dots, b_q$  ortonormální báze  $\mathcal{V}$ .

Při ortogonálním rozkladu pro body středovaného datasetu  $x'_i = v_{x'_i} + u_{x'_i}$  je poté potřeba minimalizovat chybu projekce, tedy minimalizovat:

$$\sum_{i=1}^N \|x'_i - v_{x'_i}\|^2 = \sum_{i=1}^N \|u_{x'_i}\|^2$$

Řešením minimalizace je využití ortonormální báze tvořené vlastními vektory  $b_1, \dots, b_p$  příslušejícími k vlastním číslům matice  $\frac{1}{N-1} X'^T X'$  seřazeným sestupně podle velikosti. Podprostor  $\mathcal{V}$  a matice  $V$ , která je využita k získu koeficientů projekce bodů, jsou pak tvořeny prvními  $q$  vektory této báze. [78]

PCA transformuje staré příznaky na nové komponenty, příznaky nového prostoru tak již nereprezentují stejné hodnoty. Jelikož je u této práce důležitá i vysvětlitelnost výsledků, není PCA využita pro získ nových příznaků a snížení dimenzionality. Místo toho se zde jedná pouze o analýzu, jak velký prostor statistik je potřeba, zda je potřeba zanechat všechny, nebo je možné nějaký počet vynechat. V budoucnu budou provedeny experimenty přímo s komponentami PCA místo statistik.

Pro výpočet PCA byla použita metoda knihovny scikit-learn – `sklearn.decomposition.PCA` [79] v jazyce Python a konkrétně její atribut `singular_values_`.

## 2.3 Použité modely strojového učení

### 2.3.1 Lineární regrese

Lineární regrese je model strojového učení učený pomocí supervizovaného učení. Jedná se o způsob predikce spojité vysvětlované proměnné  $Y$  pomocí vektoru příznaků  $X$  tak, aby chyba byla co nejmenší. Při predikci předpokládáme lineární závislost vysvětlované proměnné na hodnotách příznaků. Předpokládáme, že hodnota  $Y$  lze vysvětlit lineární kombinací hodnot příznaků  $X$ . Zároveň model počítá i s určitou mírou náhodnosti, nevysvětlitelnosti v datech, která je reálná.

Hodnota vysvětlované proměnné  $Y$  v bodě  $(x_1, \dots, x_p)^T$  je

$$Y = w_0 + w_1x_1 + \dots + w_px_p + \varepsilon,$$

kde  $w_0$  je nazýván intercept a jedná se o očekávanou výchozí hodnotu  $Y$  při nulových příznacích. Hodnoty  $w_1, \dots, w_p$  jsou neznámé koeficienty lineární kombinace. Hodnota  $\varepsilon$  je náhodná veličina, které odpovídá část nevysvětlitelná pomocí příznaků.

Při učení lineární regrese se hledají také hodnoty  $w_1, \dots, w_p$ , aby chyba modelu byla co nejmenší. Chyba je měřena pomocí nezáporné funkce  $L: \mathbb{R}^2 \rightarrow \mathbb{R}$ , která se nazývá ztrátová funkce s parametry skutečnou hodnotou  $Y$  a odpovídající predicí  $\hat{Y}$ . Obvykle je využívána kvadratická ztrátová funkce:

$$L(Y, \hat{Y}) = (Y - \hat{Y})^2$$

Pro využití veškeré informace v trénovacích datech se minimalizuje součet chyb přes všechny body trénovací množiny. Pro všechny dvojice trénovací množiny obsahující vektor příznaků  $x_i$  s odpovídající hodnotou vysvětlované proměnné  $Y_i$ , pro všechny hodnoty trénovací množiny  $i = 1, \dots, N$ . Pro kvadratickou ztrátovou funkci se jedná o tzv. reziduální součet čtverců s parametrem hodnotami koeficientů  $w$ :

$$\text{RSS}(w) = \sum_{i=1}^N L(Y_i, w^T x_i) = \sum_{i=1}^N (Y_i - w^T x_i)^2 = \|Y - Xw\|^2$$

Minimalizací  $\text{RSS}(w)$  je získán odhad koeficientů lineární kombinace  $\hat{w}$ . [80]

Pro výpočet lineární regrese v jazyce Python byla použita metoda knihovny scikit-learn – `sklearn.linear_model.LinearRegression` [79]

### 2.3.2 Hřebenová regrese

Hřebenová regrese nebo také  $L_2$  regularizace navazuje na regresi lineární (2.3.1), ale představuje určitou penalizaci k vyřešení problému kolinearity. Zavádí penalizační člen, který odpovídá kvadrátu normy vektoru koeficientů  $w$  s vynecháním interceptu, který nemá smysl penalizovat. Minimalizace se poté týká regularizovaného součtu čtverců, definovaného:

$$\text{RSS}_\lambda(w) = \|Y - Xw\|^2 + \lambda \sum_{i=1}^p w_i^2$$

Tento regularizovaný RSS je závislý na parametru  $\lambda$ , pro který platí  $\lambda \geq 0$ . Pro  $\lambda = 0$  nejsou koeficienty nijak penalizovány a minimalizace pak odpovídá té v lineární regresi. Pro  $\lambda > 0$  jsou více penalizovány vektory  $w$  s největšími složkami, v minimu se tedy budou upřednostňovat vektory s co nejmenšími složkami. [81]

Pro výpočet hřebenové regrese v jazyce Python byla použita metoda knihovny scikit-learn – `sklearn.linear_model.Ridge` [79]

## 2.4 Metody evaluace modelů

Evaluace modelů se provádí kvůli indikaci toho, jak bude model schopný fungovat i na nových vstupech neboli jeho schopnost generalizace. Zároveň lze díky evaluaci zjistit kvalitu jednotlivých použitých modelů a případně vybrat ten nejlepší.

### 2.4.1 Použité metriky validace

Obecně je chyba predikce měřena pomocí tzv. ztrátové funkce ozn.  $L$  s parametry původní hodnoty  $Y$  a predikce získané modelem  $\hat{Y}$ . Konkrétní použité ztrátové funkce byly  $R^2$  neboli R kvadrát a RMSE.

#### 2.4.1.1 $R^2$

$R^2$  neboli koeficient determinace. Vyjadřuje, jaký podíl variability cílové proměnné model vysvětluje. Jedná se o hodnotu mezi 0 a 1. Pokud je tedy například jeho hodnota 0.5, model vysvětluje přibližně polovinu variability vstupních dat. Je definován jako:

$$R^2 = 1 - \frac{\text{RSS}}{\text{SST}},$$

kde RSS vyjadřuje reziduální součet čtverců, již využitý v části o lineární regresi 2.3.1. V tomto případě ho lze vysvětlit jako celkovou nevysvětlenou variabilitu v datech. Je definovaný jako:

$$\text{RSS} = \sum_{i=1}^N (Y_i - \hat{Y}_i)^2$$

a SST, které vyjadřuje celkový součet čtverců, tedy veškerou variabilitu v datech. Je definovaný jako:

$$\text{SST} = \sum_{i=1}^N (Y_i - \bar{Y})^2,$$

kde  $\bar{Y}$  je výběrový průměr spočítaný z dat. Poměr nevysvětlené variability chceme co nejmenší, proto je na konci odečítán od 1 pro lepší interpretaci, často se využívá reprezentace v procentech. [82]

#### 2.4.1.2 RMSE

RMSE neboli „Root Mean Squared Error“ je metrika založená na MSE neboli střední kvadratické chybě.

MSE je definováno jako:

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (Y_i - \hat{Y}_i)^2$$

Penalizuje především velké odchylky v datech a je citlivá na to, když se v datech vyskytnou odlehle hodnoty.

RMSE je nelineárně přeškálované MSE a je definováno jako:

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - \hat{Y}_i)^2}$$

[82]

Jeho velkou výhodou je to, že má stejné jednotky jako vysvětlovaná proměnná a je tak možné se přímo podívat o kolik se průměrně predikce liší od skutečnosti.

## 2.4.2 Validační množina

Pokud má dataset dostatek dat, je evaluace rozdělena do 3 částí – *trénovací*, *validační* a *testovací*. Zároveň jsou v určitém definovaném poměru rozdělena i data. Evaluace je pak prováděna jen pro určitou část dat. To slouží zejména k nezávislému ohodnocení modelu, které bude skutečně indikovat schopnosti generalizace modelu na zcela nových datech. Proces i dataset je tak rozdělen na tyto části:

**Trénovací část** je využita k trénování konkrétních modelů se zafixovanými parametry, většinou zabírá největší poměr datasetu, jelikož se jedná o základní data, na kterých bude model natrénován.

**Validační část** je využita k ohodnocení modelu a porovnání s ostatními modely, to zahrnuje výběr nejlepší sady hyperparametrů i samotné nejlepší třídy modelů, v této části je zároveň vybrán finální model.

**Testovací část** je využita v samotném závěru procesu, kdy už je vybrán a natrénovaný nejlepší model, slouží k zjištění skutečné hodnoty generalizace na nových datech, odhaduje očekávanou chybu na jakýchkoliv nových datech.

Evaluace tímto způsobem funguje dobře pouze pro rozdělení dat takové, že data pochází se stejného rozdělení bez systematických odlišností (pokud není systematickost požadována). Chyby může způsobovat např. uspořádání dat, je potřeba tedy provést náhodnou permutaci, než budou data rozdělena. [82]

Pro náhodné rozdělení dat do množin v jazyce Python byla využita funkce z knihovny scikit-learn – `sklearn.model_selection.train_test_split` [79]

## 2.4.3 Křížová validace

V případě, že dataset má příliš málo dat na náhodné rozdělení do dvou (*trénovací* a *testovací*) až tří (*trénovací*, *validační* a *testovací*) množin, je možné využít křížovou validaci. V případě rozdělení dat na hodně malé množství by totiž nemusel model fungovat správně nebo evaluace by mohla být vychýlena neúplnou náhodností v datech.

Základní využití je pro situaci, kdy máme dostatek dat na oddělení *trénovací* a *testovací* množiny. Validační část procesu je potřeba pro objektivní výběr nejlepšího modelu a aby následný odhad chyby při generalizaci nebyl zaujatý. Místo validační množiny, tak použijeme na trénovací data postup trénování a validace pomocí  $k$ -násobné křížové validace, kde platí  $2 \leq k \leq N$ . Postup je poté takový:

- Trénovací data  $\mathcal{D}$  jsou náhodně rozdělena do  $k$  podobně velkých částí –  $\mathcal{D}_1, \dots, \mathcal{D}_k$
- Pro každé  $j = 1, \dots, k$  natrénujeme model s určitými hodnotami parametrů na datech z množiny

$$\bigcup_{i=1}^k \mathcal{D}_i \setminus \mathcal{D}_j$$

- Na množině  $\mathcal{D}_j$  je odhadnuta chyba jako  $e_j$



- Na konci procesu je vrácena průměrná chyba křížové validace jako

$$\hat{e} = \frac{1}{k} \sum_{i=1}^k e_i$$

Výsledná chyba odpovídá validování jednoho modelu s jednou sadou hyperparametrů. Proces je tedy třeba opakovat pro každé nastavení hyperparametrů, které je potřeba validovat. Pro finální nejlepší nastavení hyperparametrů modelu je potřeba model znovu natrénovat na celé trénovací množině  $\mathcal{D}$ . Jelikož je při validaci potřeba model několikrát trénovat, může být křížová validace velmi výpočetně náročná, zejména u složitějších modelů.

Pro opravdu malý počet dat, kdy nemáme dostatek ani na oddělení testovací množiny, je možné využít dvoustupňové křížové validace. Současně tak probíhá proces výběru nejlepšího modelu i odhadu jeho práce pomocí očekávané testovací chyby. Vnitřní křížová validace je využita na výběr nejlepšího modelu a vnější část je využita na odhad očekávané chyby. [82]

Pro výpočet chyby z křížové validace v jazyce Python byla využita funkce z knihovny scikit-learn – `sklearn.model_selection.cross_val_score` [79]

## 2.5 Barevné prostory

Na základě experimentů bylo zjištěno, že lidé vnímají barvy pomocí tří receptorů a je tak pro vnímání přirozené barvu zakódovávat do 3 dimenzí, konkrétně – *hue*, *chroma*, *luminance*. Rozdělení informace mezi dimenze je ale různé pro různé metody, postupně se tedy vyvinuly různé implementace těchto percepčních dimenzí ve formě různých barevných prostorů. [83]

Tato práce používá pro uložení barevné informace dat barevné prostory *RGB*, *XYZ*, *LAB*, *LCH*.

Barevný prostor *RGB* odpovídá fyzickému vnímání barvy. Oko má receptory citlivé na červenou, zelenou a modrou, veškeré vnímané barvy tak lze rozdělit na tyto 3 primární. Jednotlivé dimenze barevného prostoru odpovídají intenzitě dané barvy – R odpovídá červené, G odpovídá zelené a B odpovídá modré. Využívá aditivního mixování barev, sečtením hodnot kanálů pak vznikne celé barevné spektrum. Pokud jsou jejich hodnoty nulové, odpovídají černé, pokud jsou hodnoty na plné intenzitě odpovídají bílé. [84]

Barevný prostor *XYZ*, přesněji 1931 CIEXYZ je barevný prostor, který byl definován v roce 1931 na základě experimentů, které mapovaly veškeré barvy, které lidé dokážou vnímat. Dimenze Y odpovídá relativní luminanci a barvě odpovídající vnímání žluto-zelené. Ohledně dimenzí Y a Z lze obecně říci, že zaznamenávají další informace o tom, jak oko vnímá vlny světla různých frekvencí. [85]

Barevný prostor *LAB* byl původně vynalezen pro téměř uniformní rozložení barevné informace a tím i vnímaných rozdílů mezi barvami. Po několika letech byl vylepšen a přijat jako standard CIELAB. Dimenze L odpovídá luminanci, jasů, intenzitě. Dimenze A je první souřadnicí barvy a značí hodnotu v intervalu od červené k zelené. Dimenze B je druhou souřadnicí barvy a značí hodnotu v intervalu od modré ke žluté. [86]

Barvný prostor *LCH* stejně jako *LAB* je bližší lidskému vnímání barev. Dimenze L odpovídá opět luminanci, neboli jasů. Dimenze C odpovídá hodnotě chromy neboli intenzitě barvy, jedná se o vzdálenost od osy luminance. Dimenze H odpovídá hodnotě hue neboli odstínu barvy, jedná se o výběr samotné barvy a je počítán v úhlových jednotkách. [87]

## 2.6 Použité metriky vzdálenosti snímků

Metriky využité při vyhodnocování vzdálenosti snímků.

### 2.6.1 Euklidovská vzdálenost

Euklidovská vzdálenost nebo také  $L_2$  vzdálenost je obecná definice vzdálenosti dvou bodů v prostoru určité dimenze.

Pro dva body  $x$  a  $y$  v prostoru dimenze  $p$  je označena jako  $d_2$  a definovaná jako:

$$d_2(x, y) = \sqrt{\sum_{i=1}^p (x_i - y_i)^2}$$

[88]

### 2.6.2 $\Delta E$

$\Delta E$  je metrika využívaná pro výpočet vizuální vzdálenosti dvou barev.

Pro výpočet  $\Delta E$  jsou v práci použity snímky v barevném prostoru LAB (2.5).

V práci je použit základní vzorec pro výpočet  $\Delta E$  z roku 1976, který navazuje na Euklidovskou vzdálenost pouze pro hodnoty v LAB barevném prostoru:

$$\Delta E_{ab}^* = \sqrt{(L_2^* - L_1^*)^2 + (a_2^* - a_1^*)^2 + (b_2^* - b_1^*)^2}$$

$\Delta E$  tedy nabývá nezáporných hodnot. Důležitá je zejména hodnota 1, která značí hranici, kdy je barevný rozdíl rozpoznatelný lidským vnímáním. Čím větší má hodnotu, tím více jsou rozdíly mezi barvami rozpoznatelné – nejprve jsou hodnoty rozpoznatelné blízkým zkoumáním, poté pohledem, dále jsou barvy spíše podobné než a opačné a při velmi vysokých hodnotách okolo 100 jsou to barvy opačné.

Existují další verze  $\Delta E$  metriky, ta z roku 1994 využívá LCH barevného prostoru a je nadále upravena v roce 2000. S postupem verzí se zvyšuje přesnost, ale zároveň se přidává náročnost jejich výpočtu. Jelikož je v práci při použití  $\Delta E$  metriky zpracováváno velké množství dat, je upřednostněna rychlost výpočtu před přesností. [89]

## 2.7 Sledované statistiky

Po tom, co budou redukována data BTF modelu, je potřeba ohodnotit, zda redukce zachovala vlastnosti a chování materiálu. Sledované statistiky jsou tedy definicí postupů, které budou pro ohodnocení použity.

### 2.7.1 Vizuální porovnání

BTF data zakódovávají vlastnosti materiálu pod kombinací 81 úhlů osvětlení a 81 úhlů pohledu. Jedná se tedy o velmi komplexní data, která není možné velmi jednoduše vizuálně ohodnotit. Vyrenderovaný obrázek plochy materiálu zakódovává pouze jediný úhel osvětlení a pohledu, hodnotí tedy pouze 1 snímek z celkového počtu 6561. Nejde tak ohodnotit kvalitu redukce počtu snímků, protože v zachovaném snímku bude snímek správný a v nahrazeném bude nahrazený. Je tedy potřeba využít nějaký objekt, na který budou snímky mapovány dle úhlu osvětlení, které dopadá na danou část objektu a dle kamery, která snímá objekt z určitého úhlu.

Celková kvalita redukce a výsledné chování materiálu jsou lidsky velmi dobře hodnotitelné na objektu, který je dynamicky vystavován změně pozice osvětlení či kamery. Nejlépe pokud je současně vizualizován i objekt mapovaný původní sadou všech snímků a je tak možné porovnat množství redukce vizuální informace. Atributy, které se poté zejména zkoumají, jsou zachování vzoru, barev, struktury, správné chování odlesků a stínů materiálu při měnící se pozici světla. Také zda nevznikají nechtěné artefakty, ostré hrany či změny intenzity při změně osvětlení.

Alternativou ke zkoumání dynamického chování objektu je rendering statických obrázků objektů při více různých okolních podmínkách. Výhodou tohoto přístupu je jednoduché porovnání původního mapování snímků a mapování redukovaných snímků pomocí rozdílového obrázku, který je možné dále automaticky strojově zpracovávat a počítat statistiky o průměrné chybě.

## 2.7.2 Práh vzdálenosti

Redukce snímků je prováděna na základě určitého typu vzdálenosti, buď mezi snímky nebo mezi statistikami. Při redukci je určen určitý práh vzdálenosti a ve všech dvojicích, které mají vzdálenost menší než daný práh je jeden snímek nahrazen druhým.

Samotný práh má určité vypovídající vlastnosti o zachování množství informace v datech. Je to obecný ukazatel toho, kolik informace bylo zanedbáno, jak malá variace v hodnotách byla zjednodušena na jednu hodnotu.

## 2.7.3 Histogram

Histogram je graf, který odhaduje rozdělení množiny hodnot. Hodnoty jsou rozděleny do stejně velkých intervalů nazývané biny. Jeden sloupec grafu poté reprezentuje jeden bin a jeho výška odpovídá počtu hodnot v daném intervalu. Pro jednoduché porovnání tvarů histogramů je možné je normalizovat tak, že součet výšek všech sloupců odpovídá hodnotě 1. Výška pak reprezentuje relativní poměr hodnot v daném sloupci oproti celkovému počtu. Poté lze hovořit o odhadu rozdělení hodnot.

Ve strojovém vidění a fotografování se histogram využívá pro zobrazení rozdělení hodnot jednotlivých barevných kanálů, v některých případech kombinovaných do jednoho šedivého kanálu. Používají se zejména pro správné nastavení snímače. Histogramy u samotných snímků lze poté také vytvářet na základě hodnot intenzity či jednotlivých barevných kanálů.

Porovnávání histogramů dvou obrázků je jedna z nejjednodušších metod porovnávání dvou snímků. Oba histogramy musí mít stejné velikosti binů nebo být stejně normované. Pro porovnání histogramů v této práci byly použity 2 metriky.

První metrikou je  $\chi^2$ . Běžně se používá jako test rozdílnosti měřené a očekávané hodnoty kategorických náhodných veličin. Je to velmi obecná metrika používaná ve statistice na ověřování hypotéz. Zde je aplikována na měření rozdílnosti mezi dvěma vzorky konečného počtu hodnot histogramu. Pro porovnání dvou histogramů je použita definice:

$$D_{\chi^2} = \sum_i \frac{(h_1(i) - h_2(i))^2}{h_1(i) + h_2(i)},$$

kde  $h(i)$  je výška sloupce daného binu a součet je přes všechny sloupce. Obecně hodnota 0 je perfektní shoda, čím je hodnota vyšší, v našem případě čím více se blíží 1 kvůli normalizaci histogramů, tím je rozdíl mezi histogramy větší. Implementace je převzata z [90].

Druhou metrikou je *Kolmogorova–Smirnovova odchylka*, která popisuje rozdíl histogramů pomocí maximální odchylky sloupce spočítanou přes všechny sloupce. Pro porovnání dvou histogramů je použita definice:

$$D_{KS} = \max_i |h_1(i) - h_2(i)|.$$

Tato metrika je spíše používána na ohodnocení diskrétních bodů spojitých funkcí. Implementace je převzata z [91]. [92]

$\chi^2$  metrika je pro tuto práci důležitější, jelikož je více vhodná pro výpočet vzdálenosti diskrétních histogramů. *Kolmogorova–Smirnovova odchylka* je v práci použita spíše pro porovnání.



## Kapitola 3

# Popis dat

*Tato kapitola je věnována popisu dat, která jsou v experimentu využita. Data byla dodána vedoucím a ústavem UTIA AV ČR. Kapitola obsahuje detailní popis jak dat materiálů ve více reprezentacích, tak dat výsledků psychovizuálních experimentů zároveň s popisem experimentů samotných.*

### 3.1 Použitá měření vzhledu materiálů

Vzorová data materiálů využitá pro statistickou analýzu. Jedná se o uniformní data BTF modelu a dynamické BTF vizualizace materiálu ve formě videa. Video bylo použito při psychovizuálních experimentech, práce bude analyzovat jeho jednotlivé snímky.

Tato práce se omezuje na materiálovou skupinu dřevěných dýh. Jsou jednoduše charakterizovatelné do skupin, jelikož mají velmi podobnou strukturu a vlastnosti. Lze je popsat pomocí několika charakteristik a jsou tak jednodušeji hodnotitelné při psychovizuálních experimentech. Výsledky jsou poté dobře interpretovatelné, jelikož jsou u seskupení jasně ukázány vlastnosti jako směrovost, světlost či frekvence. Jsou to také poměrně ploché materiály, není tak třeba tolik řešit zachování dat úhlů pohledu, které jsou důležité pro prostorovou výraznost (jako např. u látek [22]). V budoucnu je ale v plánu analýzu rozšířit na další skupiny materiálů jako laky či právě látky.

Práce se zaměřuje na analýzu skupiny 30 dřev (Obr. 3.1, Obr. 3.2). Další skupina odlišných 30 dřev, na kterých byly také provedeny experimenty, je použita jako validační množina pro proces strojového učení.

Pro zpracování dat během analýzy a strojového učení byla použita reprezentace pomocí Python balíčku Numpy a jeho kontejneru `numpy.array`. [93]


#### 3.1.1 Uniformní BTF data

BTF data jsou měřena pomocí gonioreflektometru. Ten se skládá ze dvou ramen a otočného stolku držícího materiál. Na jednom rameni je připevněna industriální kamera s vysokým rozlišením, na druhém je připevněno LED osvětlení. Ramena se sklápí okolo horizontální osy v rovině vzorku, rameno se světlem se navíc otáčí kolem vertikální osy ve středu otočného stolku. Tímto nastavením vzniká téměř neomezené množství pozic pro osvětlení a kameru a tedy měření vlastností materiálu z téměř neomezeného množství úhlů osvětlení a pohledu. Efektivní rozlišení poté dosahuje 1000 DPI. Doba měření BTF dat jednoho materiálu se pohybuje okolo 10 hodin. [2]

Prakticky jsou poté BTF data měřena z různých kombinací 81 pozic osvětlení a 81 pozic kamery, což ve výsledku dává 6561 snímků pro každý materiál. Pozice začínají přímo nad měře-



■ **Obrázek 3.1** Ilustrační snímky materiálů mimo odlesk. Obrázek poskytl vedoucí práce.




■ **Obrázek 3.2** Ilustrační snímky materiálů v odlesku. Obrázek poskytl vedoucí práce.

ným objektem, kolmo k rovině na které objekt leží, na normále roviny objektu (Obr. 3.3). Pozice postupně zvyšují elevační úhel, který svírají s normálou postupně na 0, 15, 30, 45, 60 a 75 stupňů ( $\theta_2$ ). V každé této úrovni elevačního úhlu je proveden určitý počet azimutových snímků okolo objektu, konkrétně 1, 6, 12, 18, 20, 24 (# dir). To umožňuje zachytit vzhled materiálu různými kroky v azimutu, dle elevace postupně po 60, 30, 20, 18, 15 stupních ( $\Delta\phi_2$ ) a docílit tak hemisféricky rovnoměrné distribuce směrů osvětlení a pohledu. Těchto 81 pozic je použito v různých kombinacích pro kameru i světlo.

Existují kombinace pozic, kde jsou ramena ve stejné pozici a tím se kamera a světlo překrývají.



$\theta_2$	$\Delta\phi_2$	# dir
$0^\circ$	$-^*$	1
$15^\circ$	$60^\circ$	6
$30^\circ$	$30^\circ$	12
$45^\circ$	$20^\circ$	18
$60^\circ$	$18^\circ$	20
$75^\circ$	$15^\circ$	24



■ **Obrázek 3.3** Měřené pozice osvětlení a kamery. Zdroj: [94]

Řešením je pootočení ramene světla o pár stupňů vedle kamery tak, aby se nepřekrývaly.


V každém snímku jsou při následném zpracování hledány registrační značky v okolí měřeného materiálu. Na základě pozic těchto značek je provedena vzájemná registrace a transformace všech snímků na snímek odpovídající kolmému pohledu. Ten je následně oříznut a uložen. Výsledná velikost je pak pro všechny snímky jednoho materiálu stejná.

Jednotlivé materiály mají ale různé toto výsledné stejné rozlišení snímků, pro automatické zpracování více materiálů je potřeba rozlišení sjednotit, nejčastěji oříznutím v kombinaci pod-samplováním (např. pouze každý druhý pixel).

Naměřená data BTF modelu jsou uložena ve formátu OpenEXR (<https://openexr.com>), zkráceně jen EXR. Formát EXR je využíván pro ukládání a zpracování obrázků v datovém typu s plovoucí řadovou čárkou HALF nebo FLOAT ve vysoké kvalitě, zdrojová data práce mají typ FLOAT. Obsahuje obecné informace o výšce a šířce snímku v počtu pixelů, zároveň ale podporuje úpravu zobrazovaného rozsahu pomocí definice zobrazovaného okna. Je tak možné zobrazit pouze část uložených dat či rozšířit zobrazované okno na větší velikost než mají zdrojová data. EXR formát podporuje různý počet a kombinace barevných kanálů, v případě této práce se jednalo o 3 kanály XYZ barevného prostoru 2.5. Hodnoty jsou uloženy jako typ FLOAT. [95]

### 3.1.2 BTF data pro vizuální experiment

Pro vizuální experimenty byla připravena speciální dynamická data ve formě videa. Celý obraz videa vyplňuje plocha kusu materiálu pozorovaná pod úhlem  $45^\circ$ , která se ve videu otáčí tak, že stále vyplňuje celý obraz. Světlo je statické. Pozice kamery se postupně otočí v azimutu  $90^\circ$  a zpět. Díky tomu se materiál v průběhu otáčení postupně zobrazuje osvětlený z boku (tedy mimo odlesk) až do osvětlení zpřímá (tedy v odlesku) a poté zpět.



■ **Obrázek 3.4** Postupné otočení materiálu do odlesku.

Jelikož video jako formát dat není jednoduché analyzovat, byla použita analýza jednotlivých snímků. Materiál se v celém průběhu videa otočí do odlesku a zpět, druhá polovina videa je tedy redundantní. Pro následnou analýzu dat videa bylo tedy použito pouze prvních 60 snímků, které

zobrazují jeden přechod z pozice mimo odlesk do odlesku.

Pro uložení snímků videa byla využita jejich reprezentace ve formátu JPEG. JPEG je zkratka pro „Joint Photographic Experts Group“ po skupině, která formát definovala. Podporuje  $2^{24}$  barev kombinací tří 8-bitových kanálů. Nevýhody jsou zejména ztrátová komprese dat, která může zapříčinit vznik artefaktů a žádná možnost průhlednosti. V této práci jsou snímky v tomto formátu pouze čteny, s jeho nevýhodami tedy není problém.

## 3.2 Vizuální experimenty a získaná data

Pro spojení vlastností získaných lidským vnímáním a vypočítanými statistikami nad materiály byl proveden jeden typ psychovizuálního experimentu nad dvěma sadami dat.

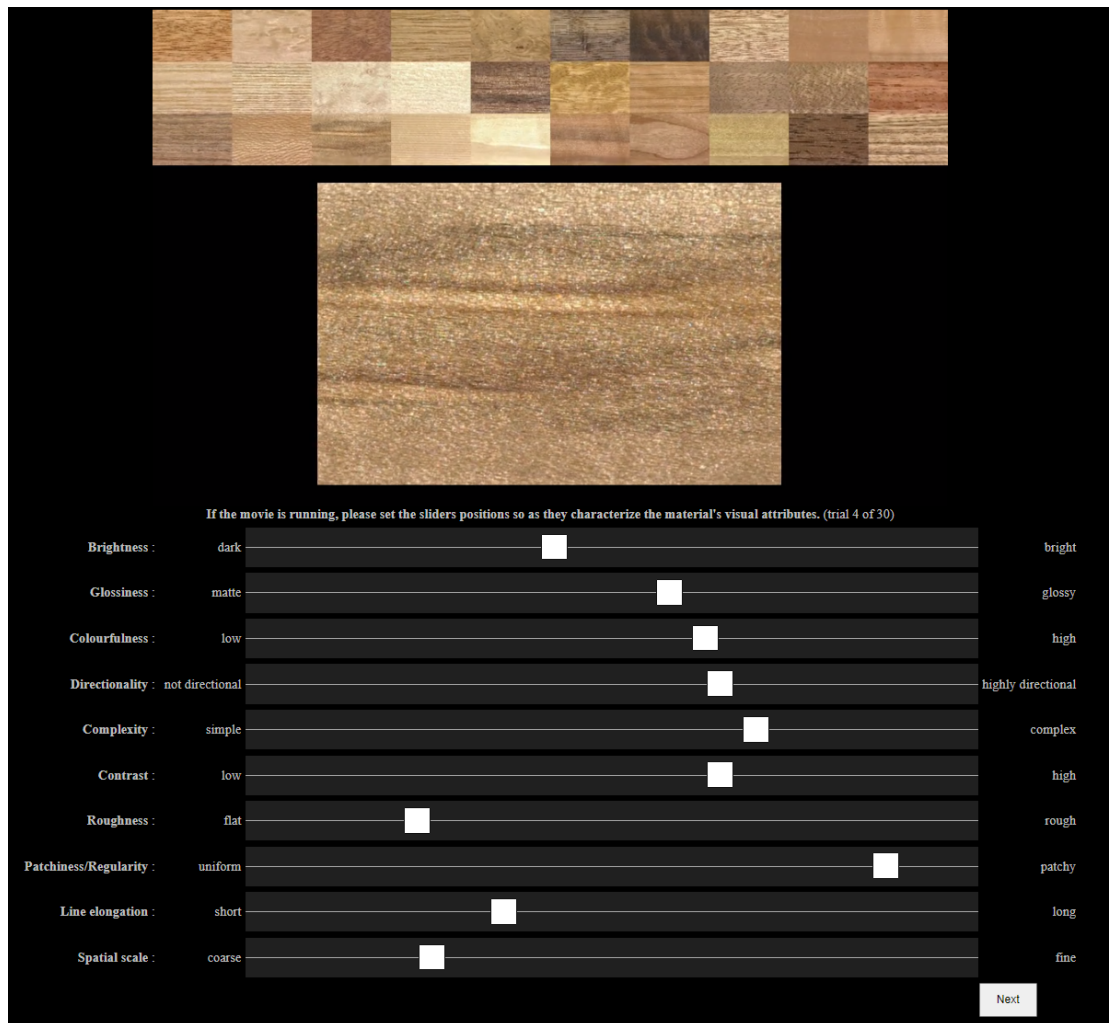
Lidé v experimentu hodnotili 10 vlastností materiálu pomocí posuvníků intenzity, konkrétně:

- Světlost („Brightness“) – od tmavý po světlý
- Lesklost („Glossiness“) – od matného po lesklý
- Barevnost („Colourfulness“) – od málo barevného po hodně barevný
- Směrovost („Directionality“) – od nesměrového po velmi směrový
- Komplexnost („Complexity“) – od jednoduchého po komplexní
- Kontrast („Contrast“) – od málo kontrastního po hodně kontrastní
- Hrubost („Roughness“) – od plochého po hrubý
- Pravidelnost („Patchiness/Regularity“) – od uniformního po různorodý
- Délka linií („Line elongation“) – od krátkých linií po dlouhé linie
- Prostorové měřítko („Spatial scale“) – od velkých širokých vzorů po malé jemné vzory

Reálná škála byla 1 až 99, číselné vyjádření se ale během experimentu u posuvníků nezobrazovalo. Během hodnocení bylo zobrazeno ve velkém rozlišení video jednoho materiálu, který byl hodnocen. Zároveň s ním v horní části obrazovky v malém rozlišení byla videa všech materiálů pro jednoduché porovnání vlastností (Obr. 3.5). Každý účastník takto postupně ohodnotil celou zkoumanou skupinu materiálů. Výsledná data byla získána jako průměr hodnocení dané vlastnosti pro daný materiál přes všechny hodnocení účastníků experimentu. Byla tak získána jedna hodnota reprezentující lidské vnímání dané vlastnosti pro daný materiál. Výsledkem byl dataset hodnocení pro 30 dřev o 10 statistikách. To vše bylo provedeno na dvou sadách po 30 materiálech.

První sadu dat ohodnotilo 45 účastníků, druhou sadu 22 účastníků. Rekrutování byli především z řad studentů psychologie Karlovy Univerzity. Studie byla schválena etickou komisí Ústavu psychologie AV ČR. [96]





■ Obrázek 3.5 Ukázka průběhu experimentu.

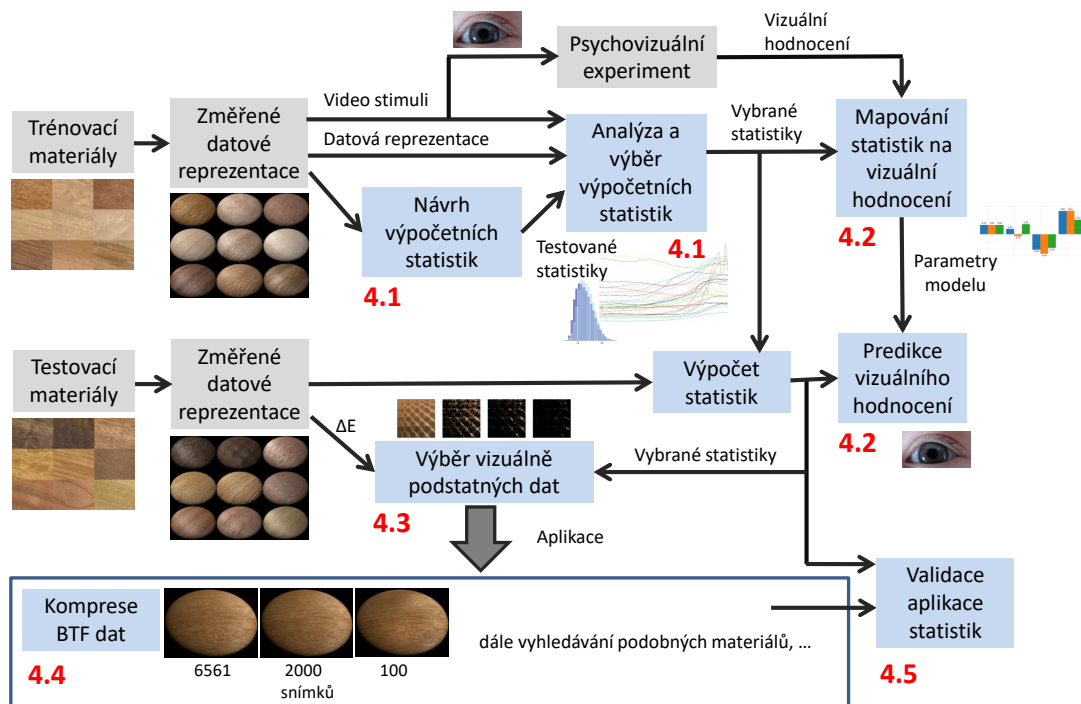


## Kapitola 4

# Analýza řešení problému

V této kapitole jsou postupně a vysvětleny jednotlivé metody a postupy, které jsou poté v praktické části konkrétně použity. Kapitola se zaměří zejména na analýzu metod, pomocí nichž je v jednotlivých krocích praktické části postupováno.

V práci je postupováno na základě tohoto schématu (červená čísla označují části kapitoly popisující danou část schématu):



Dodáno vedoucím Řešeno v práci

■ Obrázek 4.1 Schéma postupu práce.

## 4.1 Návrh výpočetních statistik, jejich analýza a výběr

Popisné statistiky získané výpočtem z dat snímku materiálu.

### 4.1.1 Výběr statistik

Výběr těchto výpočetních statistik je odvozen od lidského vnímání a zpracování obrazu. Práce se při výběru statistik inspirovala prací [15], kde byla pro výběr statistik použita iterativní metoda. Nejprve je definována počáteční množina statistik a následně provedena syntéza textur pomocí těchto statistik. U těch syntéz, které jsou z nějakého důvodu neúspěšné je následně nalezena charakterizující vlastnost, která je vystihuje. Do množiny je poté přidána statistika, která tuto vlastnost nějakým způsobem popisuje nebo charakterizuje. Zároveň je kontrolováno, že všechny původní statistiky musí být stále přítomné a pokud by byly z množiny vyřazeny, u jiných textur syntéza selže. Tento postup je vhodný zejména proto, že se výběr nesoustředí na konkrétní texturu ale na celou referenční množinu. Zároveň je opět výběr kontrolován lidským vnímáním textury po syntéze.

Základní skupinou statistik, které byly zjištěny pomocí předchozího postupu v práci [15], jsou statistiky popisující relativní intenzitu reprezentovanou pixely černobílého obrázku textury. Některé jiné modely používají přímo histogram hodnot pixelů intenzity. Komplexnější analýzu společně s některými prostorovými informacemi ale dokáže dodat skupina statistik spočítaná na hodnotách pixelů intenzity neboli luminance zahrnující:

- Normalizované momenty
  - Střední hodnota reprezentovaná průměrem
  - Rozptyl
  - Šikmost
  - Špičatost
- Rozsah
  - Maximum
  - Minimum

Tyto statistiky byly vybrány pro použití v této práci.

Práce [15] počítala pouze s černobílými obrázky a tedy pouze kanálem intenzity. Pro zachycení informace o barvě byla pro tuto práci navíc vybrána statistika, která zachycuje barevnou informaci a to:

- Průměrná barevnost

Ta je počítána na kanále chroma barevného kanálu LCH (2.5).

Dalšími statistikami zjištěnými v práci [15] jsou statistiky vázané na více-měřítkovou dekompozici a analýzu jejich koeficientů. Tyto statistiky se soustředí zejména na periodicitu, opakující se globální prvky v textuře, strukturu textur a rozlišení linií a hran vznikající odraženým světlem a souvisejícím stínem na povrchu materiálu. Těchto statistik získaných pomocí koeficientů více-měřítkové lineární dekompozice je velké množství (např. Gabor features [97]) a může být obtížné je získat. V této práci byly nahrazeny statistikami, kterých je méně a jsou výpočetně jednodušší, snaží se ale postihnout stejné vlastnosti textur. Byly počítány pouze na kanálu luminance barevného prostoru LCH (2.5):

- Frekvence
  - Nízké

- Střední
- Vysoké
- Směrovost

Frekvence jsou získané z frekvenční výkonové spektrální hustoty („Power Spectral Density“ – PSD) vypočítané pomocí Fourierovy transformace na textuře. Ty pomáhají s analýzou hran textury.

Směrovost, převzatá z prací [70, 71], využívá poměry hodnot frekvencí získaných pomocí Fourierovy transformace v různých částech textury. Poměry poté transformuje na informace o směrovosti linií v textuře.

Definice vybraných statistik je provedena v teoretické části (2.1).

### 4.1.2 Analýza statistik

Analýza výpočetních statistik zjišťuje, zda dobře zachycují požadované vlastnosti textur. Díky tomu je poté možné uvažovat o mapování výpočetních statistik a vizuálních statistik získaných hodnocením videa v experimentu pozorovatelem. Analýza je provedena na snímcích videa použitého v psychovizuálním experimentu v kombinaci s odpovídající podmnožinou změřených BTF dat.

V práci je provedena analýza hodnot statistik jednotlivých snímků videa. Speciálně byly analyzovány snímky 9 a 51, jelikož odpovídají materiálu mimo odlesk (azimut světla kolmo na azimut směru pohledu) a v odlesku (azimut světla proti azimutu pohledu). V dalších částech práce je poté používána průměrná hodnota přes všechny snímky, PCA analýza a korelace statistik mezi sebou již analyzuje tuto průměrnou hodnotu.

Je také provedeno základní porovnání hodnot intenzity obou typů dat (video, BTF) pomocí histogramů. Porovnávány jsou snímky pro směry osvětlení a pohledu BTF materiálu odpovídající směrům, které zobrazuje video, tedy statické světlo, elevace kamery na 45 stupňů a proměnný azimut kamery v rozsahu 0 až 90 stupňů. Porovnání je provedeno stejným způsobem jako při ohodnocování výsledků redukce dat, tedy pomocí vzdáleností histogramů definovaných v teoretické části sledovaných statistik (2.7.3).

Byla také provedena analýza korelace (2.2.1) jednotlivých výpočetních statistik mezi sebou a PCA analýza (2.2.2) na celém datasetu spočítaných statistik. Tento typ analýzy je určen zejména pro část mapování statistik na vizuální hodnocení, kde jsou tyto znalosti o datasetu použity pro optimalizaci metod strojového učení.

Po provedení experimentů je ještě zpětně zkontrolována funkce statistik vypočítaných na snímcích videa pomocí korelace (2.2.1) s hodnoceními pro vizuální statistiky získanými z experimentu.

### 4.1.3 Generalizace vlastností statistik

Důležitým předpokladem práce je generalizace vlastností statistik zjištěných v analýze. Video použité v psychovizuálním experimentu představuje pouze omezené množství směrů pohledu a osvětlení – elevační úhel pohledu 45 stupňů a azimuty 0 až 90 stupňů a statické světlo na elevaci 45 stupňů a azimutu 180 stupňů. Tomu v uniformně změřených datech BTF modelu odpovídá pouze 6 snímků. Je tedy potřeba tvrzení o vlastnostech statistik zjištěných v analýze generalizovat na libovolné směry osvětlení a pohledu, aby bylo možné popsat všechny snímky BTF dat.

Ve statistické analýze byla pro elevaci 45 stupňů zjištěna dobrá korelace mezi výpočetními statistikami a hodnocením lidsky vnímaných vlastností. Za předpokladu, že korelace bude zachována pro jakoukoliv jinou úroveň elevace, lze zjištěné výsledky uplatnit na kompletní BTF data nezávisle na elevaci. V práci jsou tedy generalizovány výsledky získané pro omezenou kombinaci

směrů uhlů pohledu a osvětlení na všechny kombinace směrů a osvětlení. To nám umožní využít výpočetní statistiky pro statistický popis všech obrazů v BTF datech.

## 4.2 Mapování statistik na vizuální hodnocení a jeho predikce

Pro zjištění zda výpočetní statistiky skutečně zachycují lidské vnímání materiálů je potřeba je porovnat s hodnocením jednotlivých vizuálních atributů lidského vnímání. Práce se tedy snaží vysvětlit průměrné hodnocení jednotlivých vizuálních vlastností materiálu získané z psychovizuálních experimentů (3.2) ve formě spojitých proměnných pomocí sady spojitých příznaků (statistik) vypočítaných na zdrojových fotografiích materiálů (video, BTF). Jedním ze způsobů jak tento problém řešit je použití regrese.

Jelikož se prováděný výzkum snaží o jednoduchou vysvětlitelnost vizuálních hodnocení materiálů pomocí výpočetních statistik, byly zvoleny dva základní modely.

Jako první model byla použita *lineární regrese* (2.3.1). Mapuje kombinaci hodnot výpočetních statistik lineárně na danou statistiku vizuální. Z velikosti koeficientů je možné jednoduše zjistit podíl jednotlivých výpočetních statistik na vysvětlení dané vizuální statistiky.

Po prozkoumání všech vypočtených statistik na testovací množině 30 materiálů pomocí korelace a PCA analýzy (4.1), byla zjištěna možná lineární závislost statistik mezi sebou, jako druhý model byla tedy vybrána *hřebenová regrese* (2.3.2), která regularizuje koeficienty a snižuje tak problém kolinearity statistik.

Oba modely jsou na základě hodnot koeficientů jednoduše vysvětlitelné, rychlé a není třeba je dlouho trénovat či nastavovat. U lineární regrese není žádný hyperparametr, u hřebenové pouze parametr velikosti regularizace.

Práce je zaměřena hlavně na vysvětlení vizuálních statistik těmi výpočetními. Samotná predikce na nových datech je ale také důležitou aplikací tohoto postupu. Je pak možné předvídat lidské hodnocení vlastností materiálu pomocí statistik, které jsou spočítány na datech. Je to krok k nahrazení lidského pozorovatele pro identifikaci materiálů a jejich vlastností.

Pro ohodnocení generalizace modelů byly využity dva přístupy.

Přístup *pomocí validační množiny* (2.4.2) má výhodu představení nových dat, což je u materiálů důležité, jelikož jsou obecně velmi různorodé. Zároveň i rychlost samotného výpočtu modelu, který je potřeba dělat pouze jednou pro jednu sadu dat. Nevýhodou je potřeba dlouhé přípravy dat, zejména konání psychovizuálních experimentů pro samotný zisk referenčních dat.

Přístup *pomocí křížové validace* (2.4.3) je oproti tomu méně přesný a nepřináší nová data. Model je navíc třeba trénovat a vyhodnocovat mnohokrát a postup je tak výpočetně náročnější. Zde je použit zejména kvůli malému počtu dat, trénovací množinou je pouze 30 záznamů.

Samotné metriky pro měření kvality modelu byly použity dvě.

$R^2$  (2.4.1.1) bylo využito pro informaci, jak velkou část vizuální statistiky daný model vysvětluje. Jednoduše ukazuje jak velkou část lidského vnímání vlastnosti se podařilo modelu zachytit. Prakticky jakékoliv hodnoty nad 0.5 jsou přijatelné.

$RMSE$  (2.4.1.2) bylo použito zejména kvůli informaci o průměrné odchylce modelů při predikci od očekávané hodnoty ve stejných jednotkách jako hodnota původní. V některých případech kdy  $R^2$  metrika nedávala žádné výsledky (hodnoty 0 či menší) bylo možné změřit velikost chyby modelu, i když nezachytil žádnou informaci o vizuálních statistikách a predikoval špatně.


## 4.3 Výběr vizuálně podstatných dat

BTF data obsahují fotografie vzhledu materiálů pro 81 směrů pohledu a 81 směrů osvětlení, celkem tedy 6561 snímků. Velká část těchto dat je nadbytečná. Některé snímky je možné nahradit jim podobnými snímky změřenými z jiné kombinace směrů osvětlení a kamery při sou-

časném dostatečném zachování vizuální informace. Nalezení takové množiny důležitých snímků, které mohou nahradit ostatní, je označeno jako výběr vizuálně podstatných dat. Takovýto výběr pro dostatečně kvalitní reprezentaci materiálu je proveden na základě podobnosti jednotlivých snímků. Pokud jsou si porovnávané snímky příliš podobné, je to známkou redundance informace. Jeden tak může být nahrazen druhým a informace zůstane dostatečně stejná. Na konci výběru zůstanou snímky, které zachycují tolik vizuální informace, kolik bylo požadováno na základě nastavení prahu podobnosti. Jedná se o zmenšení počtu dat na principu vektorové kvantizace, kdy je soubor datových bodů nahrazen jinými na základě určité metriky. V této práci je porovnávána redukce na základě Euklidovské vzdálenosti (2.6.1) navržených výpočetních statistik spočítaných na jednotlivých snímcích s redukcí standardním přístupem používajícím  $\Delta E$  (2.6.2) vzdálenosti jednotlivých snímků.

Konkrétněji pokud je zadaný práh vyšší než vzdálenost snímků, je provedeno nahrazení. Nahrazován je vždy snímek s vyšším elevačním úhlem pohledu od normály plochy měřeného objektu (Obr. 3.3), jelikož tyto snímky s vyšším elevačním úhlem mají vyšší zkreslení kvůli vychýlenějšímu úhlu měření. Práh vzdálenosti je arbitrárně nastavován na základě ponechaného počtu snímků.

Pro každý materiál a konkrétní typ vzdálenosti je nejprve vytvořena vzdálenostní matice snímků (Obr. 4.2), která zaznamenává vzdálenost všech jednotlivých snímků jednoho materiálu mezi sebou. Matice je potřeba pro jednodušší analýzu, zejména proto, aby při zkoušení různých



■ Obrázek 4.2 Vzdálenostní matice Euklidovské vzdálenosti statistik prvního materiálu.



hodnot prahu vzdálenosti nebylo třeba počítat je všechny znovu. Výpočet všech vzdáleností je totiž výpočetně nejnáročnější částí celého procesu. Samotný výběr vizuálně podstatných dat na základě prahů už není tolik výpočetně náročný, jelikož se jedná pouze o průchod hodnotami matice a zaznamenávání indexů snímků.

Pokud by požadovaný práh vzdálenosti byl znám již před výpočtem, lze výpočet optimalizovat tak, že není třeba počítat všechny vzdálenosti a tvořit vzdálenostní matici. Pro již jistě nahrazené snímky by nebylo třeba vzdálenosti vůbec počítat. Jelikož je ale pro každý materiál práh zachování vizuální informace jiný (jak již bylo zjištěno v [66]), není pro materiály předem jasné, kolik vizuální informace daný práh zachová. Kvůli hledání správné hodnoty prahu je tedy optimálnější jednou spočítat všechny vzdálenosti a vytvořit vzdálenostní matici.

První metodou použitou pro výpočet vzdálenosti snímků je pomocí  $\Delta E$  metriky, konkrétně jde o vzdálenost na základě průměrného rozdílu hodnot pixelů měřeného pomocí  $\Delta E$  metriky 2.6.2 v barevném prostoru LAB (2.5).

Hlavní nevýhodou této metody je její výpočetní náročnost při výpočtu vzdálenostní matice. Porovnání všech snímků mezi sebou po hodnotách pixelů je pro 6561 snímků velmi náročné a vyžaduje mnohé optimalizace. Pro základní velikost 256x256 pixelů nedoběhne algoritmus v čase několika hodin. Je tedy třeba výrazné zmenšení dat, zde na 100x100 pixelů, a optimalizace samotného způsobu výpočtu pro výpočet během jedné hodiny. Zmenšení velikosti je sice výrazné, ale data stále dobře reprezentují daný materiál, zejména díky jeho vlastnosti homogenity.

Výhodou tohoto způsobu je, že díky měření vzdálenosti jednotlivých pixelů zkoumá lokální vzdálenosti a zachovává informace o lokální struktuře. Tím zachytí lokální strukturu materiálu a bude ve výsledku v tomto ohledu pravděpodobně přesnější.

Druhou metodou výpočtu vzdálenosti snímků je pomocí *Euklidovské vzdálenosti výpočetních statistik*. Tato metoda se soustředí na globální vlastnosti jednotlivých snímků měřených pomocí v práci testovaných výpočetních statistik. Pro každý snímek materiálu jsou nejprve vypočítány a uloženy požadované výpočetní statistiky, následně je spočítána vzdálenost těchto statistik pomocí euklidovské metriky.

Její velkou výhodou je rychlost. Výpočet vzdálenostní matice je velmi jednoduchý, jelikož se jedná o výpočet Euklidovské vzdálenosti několika málo hodnot statistik, konkrétně v této práci se jedná pouze o 11 hodnot. Další výhodou je zachycení globálních vlastností materiálu bez nutnosti vzájemného porovnávání jednotlivých pixelů. V této práci je navíc výběr statistik podložen korelací s vizuálními vlastnostmi a mapováním pomocí strojového učení. Lze tedy také říci, že zde vzdálenost statistik do velké míry reprezentuje vzdálenost vizuálních vlastností.

Nevýhodou je méně přesná reprezentace lokální struktury materiálu. Je pravděpodobné, že výsledná množina vizuálně podstatných dat nebude konzistentní ani tolik přesná jako porovnávání pomocí jednotlivých pixelů jako u první metody.

Celkově lze říci, že pokud není problémem časová složitost, výběr vizuálně podstatných dat na základě  $\Delta E$  metriky bude pravděpodobně vhodnější, jelikož je lokálně přesnější. Výběr pomocí výpočetních statistik je ale rychlejší, je tedy vhodné ho použít pro velké datasety materiálů. Navíc je zde navázán na vizuální vlastnosti a je tedy vhodný pro výzkum spojený s lidským vnímáním vlastností. Do budoucna je plánováno analyzovat určitou kombinaci obou metod, která by zachovala lokální strukturu i globální vlastnosti uchované ve statistikách.

## 4.4 Aplikace výsledků na kompresi dat

Praktickou aplikací nalezení vizuálně podstatných snímků je redukce dat. Pro redukci je hledán práh vzdálenosti tak, aby byl dostatečně omezen počet snímků a tedy data zmenšena na požadovanou velikost. Zároveň je ale třeba, aby vizuální informace uložená v datech zůstala dostatečná pro správné zobrazení vlastností materiálu pro lidské vnímání.

Rozdělení hodnot vzdáleností snímků se liší pro různé materiály. Každý má tedy různý průběh poměru prahu vzdálenosti a počtu ponechaných snímků po redukci na základě daného prahu.



Práh vzdálenosti je tedy hledán experimentálně, jelikož každý materiál pro daný počet zachovaných snímků potřebuje jiné nastavení prahu.

Důležitým rozdílem oproti samotnému výběru vizuálně podstatných dat (4.3) je uložení informace o tom, které ponechané snímky nahrazují které redukované. Proces začíná s maticí indexů velikosti 81x81, která je vyplněna indexy snímků od 0 do 6560, každý index reprezentující danou kombinaci pozice světla a pozice kamery od nejnižších úhlů pozic kamery a světla od normály po vyšší (Obr. 3.3). Hlavním indexem je pozice kamery, druhým indexem je pozice světla.

Jako první je brán snímek s nejnižším úhlem pozice kamery a světla od normály, tedy s indexem 0. K porovnání vůči němu jsou brány všechny snímky, které mají vyšší index. Zkoumaný snímek nahradí všechny snímky se vzdáleností nižší než daný práh vzdálenosti a na jejich index je v matici indexů napsán index zkoumaného snímku. Zároveň tyto nahrazené snímky už nebudou uvažovány jako kandidáti pro ponechání a nahrazování dalších snímků. Poté je pro výpočet vzdáleností brán snímek s prvním vyšším nenahrazeným indexem a k němu opět všechny snímky s vyšším indexem. Takto je postupně prozkoumána celá matice indexů. Výsledkem je poté matice indexů ponechaných snímků na všech pozicích, které dle výpočtu nahrazují. Tato matice následně může být použita pro vyhledání snímku, který bude zobrazen za daných podmínek osvětlení a kamery.

Zachování sledovaných statistik (2.7) u redukované množiny dat je kontrolováno na závěr pomocí 3D objektů vizualizovaných pouze získanou podmnožinou snímků všech BTF dat. Zde je využita právě matice indexů pro zjištění, které snímky na které pozice mapovat. Poté je zde možné porovnat, zda důležité snímky dostatečně zachovaly vizuální informaci o vlastnostech materiálu.

Další aplikací kromě redukce pak může být například vyhledávání vizuálně podobných materiálů či kategorizace materiálů do skupin.

## 4.5 Validace aplikace statistik

Validace a zjištění kvality aplikace statistik, v této práci se jedná pouze o redukci dat, je provedeno pomocí sledovaných statistik popsaných v teoretické části (2.7).

*Vizuální porovnání* (2.7.1) hodnocená lidským vnímáním je nejdůležitější částí hodnocení kvality redukce dat. Ukazuje nejlépe hlavní cíl redukce a to zachování vnímaných vlastností materiálu i po redukci.

Problémem je zejména objektivnost hodnocení o zachování dostatečného množství informace, které závisí na konkrétním pozorovateli. Řešením jsou psychovizuální experimenty s větším množstvím účastníků, kteří by výslednou BTF vizualizaci ohodnotili. Tento postup je ale velmi časově náročný na přípravu, ať už jde o samotný experiment, vzorová data, způsob hodnocení či vyhodnocování výsledků. V této práci bylo z časových důvodů využito pouze subjektivní hodnocení zachování vlastností společně v kombinaci s dalšími metodami hodnocení kvality redukce.

Při přípravě BTF vizualizací s redukovanými daty byla redukce ohodnocena na renderovaném objektu s možností manuálně měnit pozici světla a zkoumat tak složitější chování materiálu. Pro vizualizaci výsledků v rámci této práce bylo využito statických snímků objektu mapovaného redukovanými daty s různými směry osvětlení. Ty budou porovnávány se snímky objektu mapovaného všemi daty ve stejných podmínkách. Jasný rozdíl bude ukázán pomocí rozdílového snímku.

*Práh vzdálenosti* (2.7.2) je druhou metodou ohodnocení kvality redukce. Je navázán už na samotný proces redukce, která má na výběr ze dvou parametrů, které spolu souvisí – počet ponechaných snímků a práh vzdálenosti. Počet ponechaných snímků označuje požadovanou datovou velikost výsledné reprezentace a práh vzdálenosti označuje množství zachované informace. V práci byl jako parametr redukce zvolen počet snímků, práh vzdálenosti je tak možné použít pro ohodnocení ztracené vizuální informace při dané redukci daného materiálu.

U  $\Delta E$  metriky je hodnota prahu přímo navázána na lidské vnímání rozdílů. Konkrétně hodnota 1 zaznamenává hranici vzdálenosti, kterou lidské vnímání zvládne zachytit. Pro výpočetní

statistiky a jejich Euklidovskou vzdálenost zatím žádné takové hodnocení neexistuje, šlo by ale pomocí dalšího výzkumu a experimentů s lidským vnímáním podobnou prahovou škálu sestavit. Velký problém s vytvořením jednotného hodnocení pomocí prahu vzdálenosti je fakt, že redukce závisí na typu materiálu, jak bylo zjištěno už v práci [66]. I přesto lze práh vzdálenosti zkoumat a získat tak informaci o množství redukce vizuální informace, která byla v datech zaznamenána.

*Porovnání histogramů* je nejjednodušší ale nejlépe objektivně hodnotitelnou metodou určení kvality redukce. Konkrétně se jedná o porovnání histogramů BTF vizualizace objektu s plnými daty a BTF vizualizace objektu s redukovanými daty. Ukazuje, zda redukce zachovala rozdělení hodnot barevných kanálů či kanálu intenzity. Z této metody nelze zjistit mnoho o zachování lidském vnímání vlastností materiálů, porovnává ale detailněji zachování rozdělení hodnot.

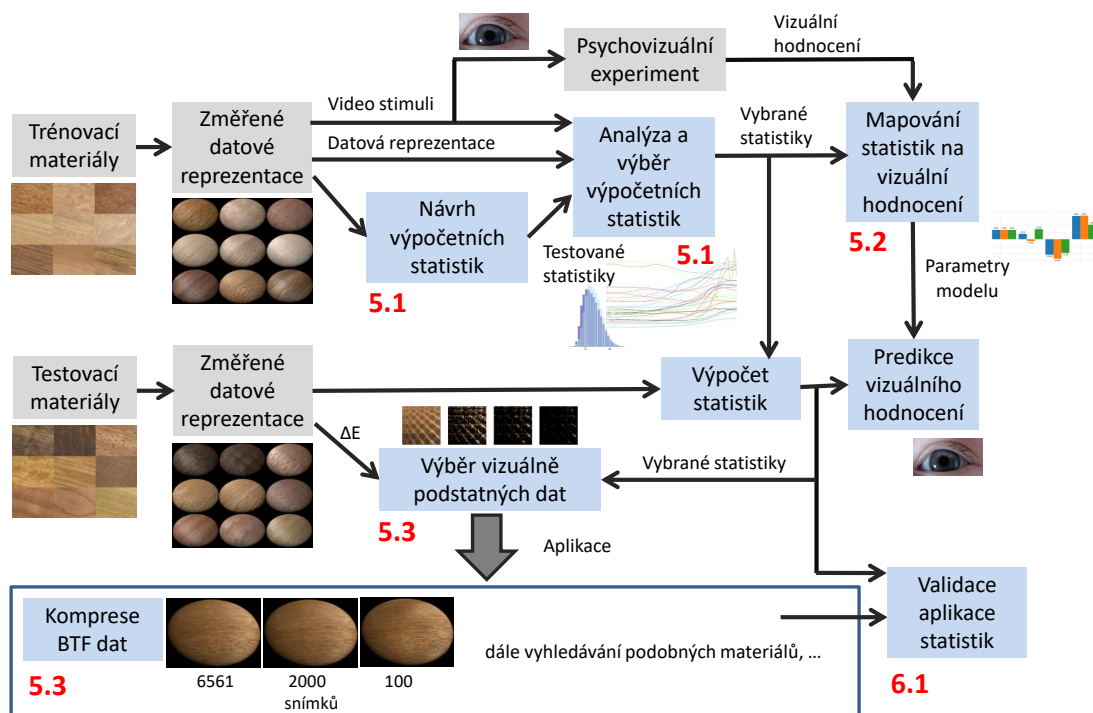
Pro porovnání byly použity dvě metriky –  $\chi^2$  a *Kolmogorova–Smirnovova odchylka*. Metrik pro porovnání histogramu je mnoho [98], pro tuto práci byly vybrány tyto dvě nejpoužívanější.

# Kapitola 5

## Praktická část

*Samotná praktická implementace postupu a průběžné výsledky.*

Stejně jako v analytické části i v praktické současně s analýzou výsledků je postupováno podle tohoto schématu:



Dodáno vedoucím    Řešeno v práci

■ **Obrázek 5.1** Schéma postupu práce.

## 5.1 Analýza dat


Jak již bylo vysvětleno (4.1), pro analýzu bylo vybráno jedenáct statistik *maximum*, *minimum*, *průměr*, *rozptyl*, *šikmost*, *špičatost*, *směrovost*, *nízké frekvence*, *střední frekvence*, *vysoké frekvence* a *barevnost*.

### 5.1.1 Analýza snímků videa

Nejprve byla provedena analýza snímků videa (3.1.2). Byl zkoumán průběh statistik *maximum*, *minimum*, *průměr*, *rozptyl*, *šikmost*, *špičatost* přes všech 60 snímků. Vždy byl načten snímek, převeden do barevného prostoru LCH (2.5), spočítána daná statistika pro daný kanál snímku a uložena její hodnota. Takto byly spočítány statistiky přes všech 60 prvních snímků pro všech 30 materiálů. Každá statistika byla vykreslena do samostatného grafu, pro kompaktnost byly ale najednou vykresleny průběhy všech materiálů. Materiály jsou v grafu označeny svými indexy podle těchto referenčních kompozic ukázkových snímků (oba obrázky poskytl vedoucí práce):



■ Obrázek 5.2 Reference mimo odlesk.




■ Obrázek 5.3 Reference v odlesku.

Například graf průměru (Obr. 5.4) poté ukazuje, že čím blíže je snímek odlesku, tím vyšší je průměrná luminance snímku, což intuitivně odpovídá chování materiálu při měnícím se osvětlení, které je použito pro video.


Graf průběhu maxima (Obr. 5.5) ukazuje, že strojová reprezentace materiálu není schopná zachytit rozdíly v maximální luminanci různých materiálů v odlesku. U vyšších indexů snímků je vidět zastropování na hodnotě 100, což je maximální strojově měřená hodnota luminance. Pravděpodobně by graf přirozeně pokračoval s vyššími hodnotami. Samotná BTF data jsou změřena v HDR a zastropování by se tak u nich neprojevovalo.

Oproti tomu graf průběhu minima (Obr. 5.6) ukazuje, že minimální hodnota se nemění tolik globálně přes všechny snímky videa. Osvícení materiálu až do odlesku tak spíše umocňuje maximální hodnoty luminance a neovlivňuje minimální. V odlesku tak pravděpodobně budou více viditelné rozdíly v hloubkové struktuře zaznamenané pomocí stínů a odlesků, jelikož jsou větší rozdíly v minimálních a maximálních hodnotách. Mimo odlesk zase budou pravděpodobně lepší informace o povrchu a jeho barvě, jelikož se neztrácí informace kvůli přesvícení.

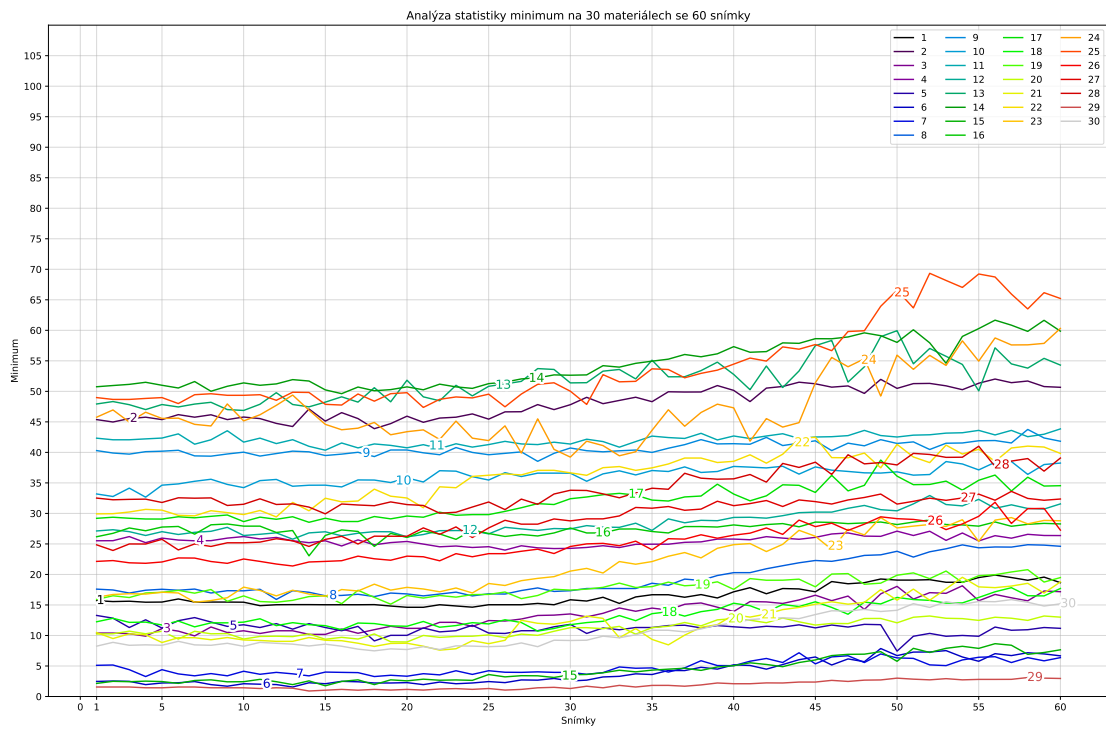
To potvrzuje i graf průběhu rozptylu (Obr. 5.7), který ukazuje, že čím blíže odlesku je materiál, tím větší je rozptyl v hodnotách luminance. Výrazné zvýšení rozptylu je ale pozorováno jen u některých materiálů, typicky s hrubým povrchem, kdy jsou stíny zvýrazněny jeho nerovnosti. Například materiál číslo 9 neprokazuje téměř žádné zvýšení rozptylu v průběhu videa. Jak je možné vidět z referenčních snímků, jedná se materiál, který není velmi lesklý a jeho snímky mimo odlesk a v odlesku jsou si velmi podobné. Oproti tomu materiál číslo 8 vykazuje výrazné



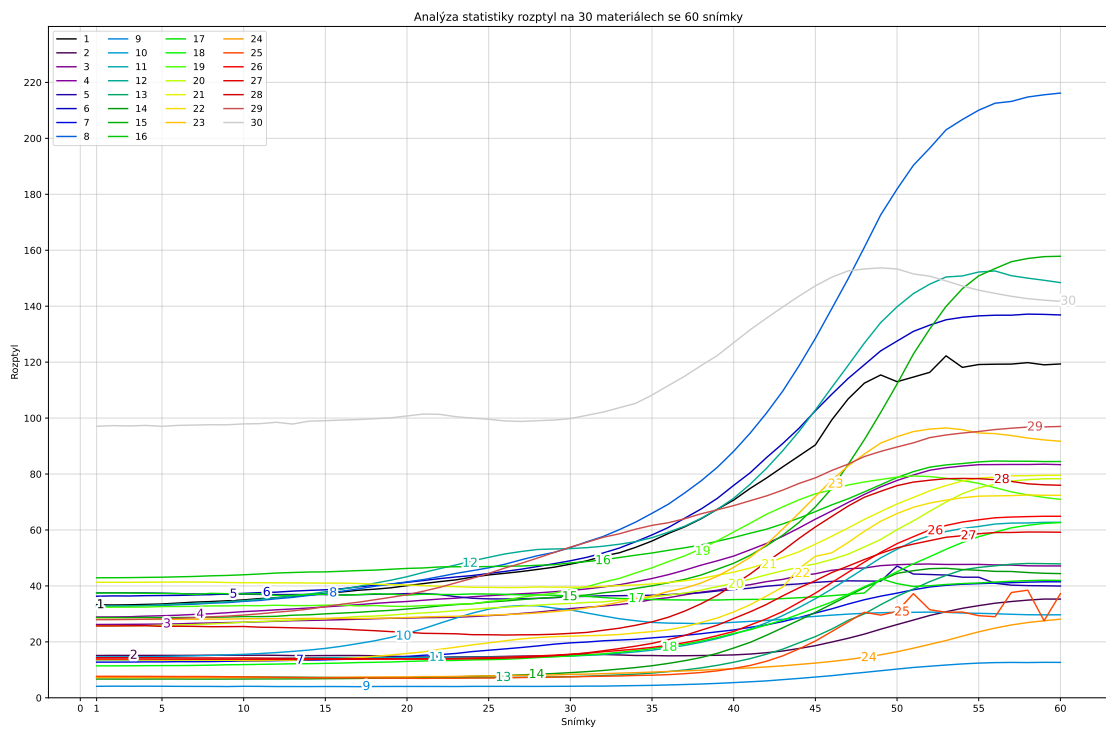
**Obrázek 5.4** Průběh hodnoty průměru přes 60 snímků pro 30 materiálů.



**Obrázek 5.5** Průběh hodnoty maxima přes 60 snímků pro 30 materiálů.



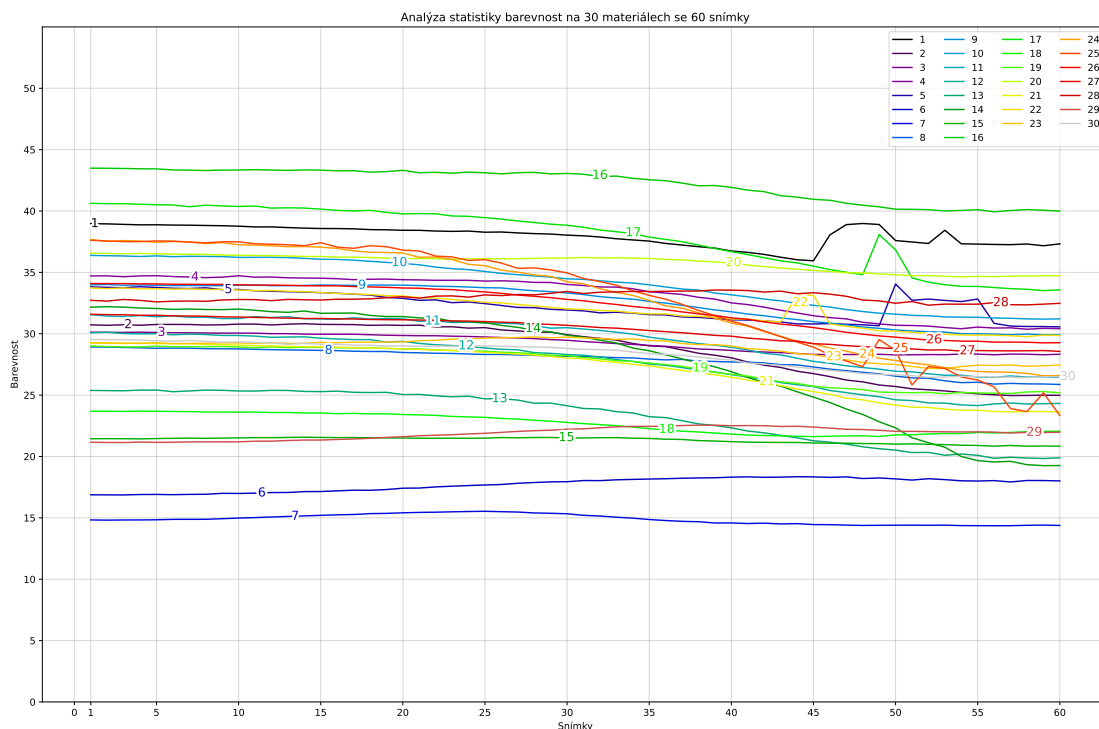
■ Obrázek 5.6 Průběh hodnoty minima přes 60 snímků pro 30 materiálů.



■ Obrázek 5.7 Průběh hodnoty rozptylu přes 60 snímků pro 30 materiálů.

zvýšení rozptylu hodnot při přechodu do odlesku, což je možné pozorovat i na referenčních snímcích, kde je vidět výrazné zesvětlení a zvýraznění tmavých čar povrchu.

Průměrná hodnota barvy, jak je možné vidět v grafu průběhu barevnosti (Obr. 5.8) se v prů-



■ Obrázek 5.8 Průběh hodnoty barevnosti přes 60 snímků pro 30 materiálů.

běhu videa příliš nemění. Je to pravděpodobně kvůli tomu, že osvětlení ovlivňuje hlavně kanál luminance a kanál chromy je v průběhu videa ovlivňován minimálně. To ale může být rozdílné pro jiné typy materiálů jako například autolaky, které při osvětlení mění částečně i svou barvu.

Další grafy pro statistiky *šikmost a špičatost* jsou přiloženy v příloze (Obr. A.1, Obr. A.2). Například šikmost souvisí s lidským vnímáním lesklosti povrchu. Materiály s pozitivní hodnotou šikmosti jsou vnímány jako tmavší a lesklejší než materiály s šikmostí nižší [99].

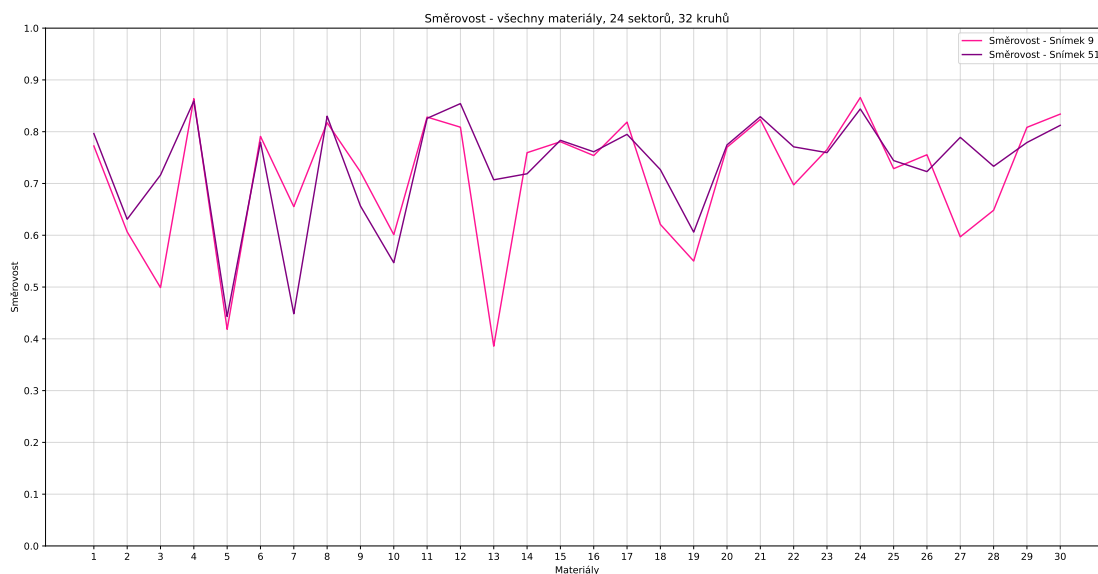
### 5.1.2 Analýza směrovosti a frekvencí

Jelikož je výpočet frekvencí a směrovosti poměrně náročný, byla provedena analýza jen na důležitých snímcích 9 a 51. Snímek 9 zaznamenává typické chování materiálu mimo odlesk, snímek 51 zaznamenává typické chování materiálu v odlesku. Samotný další výpočet a mapování výpočetních statistik na vizuální hodnocení budou už provedeny s hodnotami všech 60 snímků.

Směrovost byla spočítána postupem popsáním v teoretické části (2.1) s 24 kruhovými výsečemi a 32 kružnicemi rozdělujícími kruh frekvencí od středu. Takto jemné rozdělení se ukázalo jako přesnější pro zaznamenání směrovosti materiálu. Při výpočtu směrovosti se počítá azimutově závislé chování materiálu zaznamenané jako poměry hodnot frekvence v jednotlivých částech amplitudového spektra ohraničených úsečkami a kružnicemi. Jemnější rozdělení tak lépe zachytí lokální poměry jednotlivých částí.

Na samotném grafu směrovosti pro snímky 9 a 51 pro všechny materiály (Obr. 5.9) je možné vidět rozdíly v hodnotách pro jednotlivé materiály a zároveň rozdíly pro materiál v odlesku a mimo odlesk. Je možné vidět vysoké hodnoty u materiálů číslo 4, 11 a 30 a nízké hodnoty pro



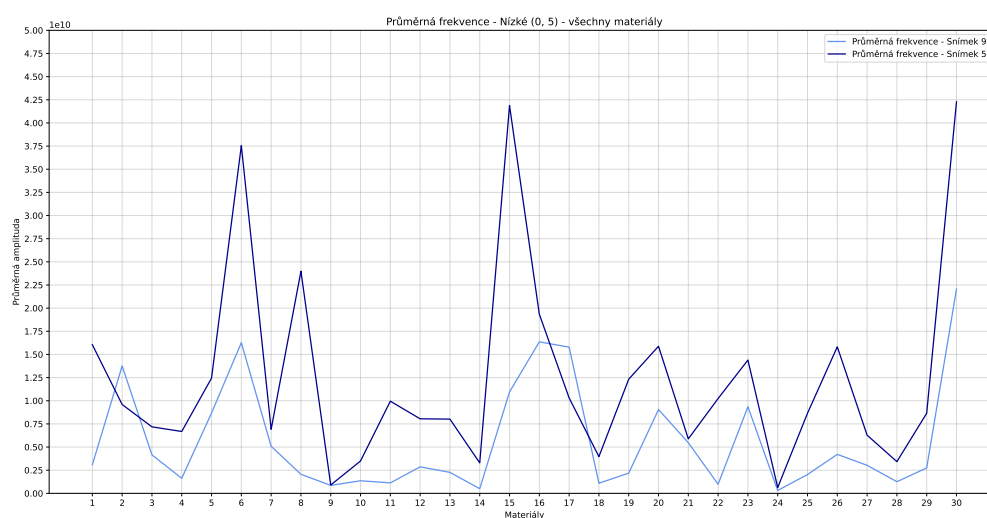


■ **Obrázek 5.9** Směrnost snímků 9 a 51 přes všechny materiály.

materiály 5, 13, 19 což při prozkoumání referenčních snímků materiálů odpovídá realitě. Zajímavé je, že u některých materiálů se hodnoty velmi liší pro snímky mimo odlesk a v odlesku, například pro materiály číslo 3 či 13. Pravděpodobně bude důvodem zvýraznění struktury materiálu v odlesku. Za zmínku stojí, že hodnoty směrností všech materiálů jsou rozmístěny v poměrně úzkém intervalu od 0,4 do 0,9. Je zde možná souvislost s tím, že dřevěné dýhy jsou obecně spíše směrové materiály. V budoucnu bude zajímavé pozorovat, zda se hodnoty směrnosti budou pro jiné typy materiálů více lišit.

Analýza frekvenční výkonové spektrální hustoty souvisí s hloubkovou a strukturální analýzou materiálu. Nízké frekvence zaznamenávají větší prvky ve struktuře materiálu, vysoké naopak malé jemné prvky. Obecně je v grafech možné vidět vyšší hodnoty amplitud pro snímek v odlesku, což potvrzuje předchozí domněnku, že odlesk zvýrazňuje strukturu materiálu.

Na grafu nízkých frekvencí (Obr. 5.10) je možné vidět vysoké hodnoty amplitud v odlesku

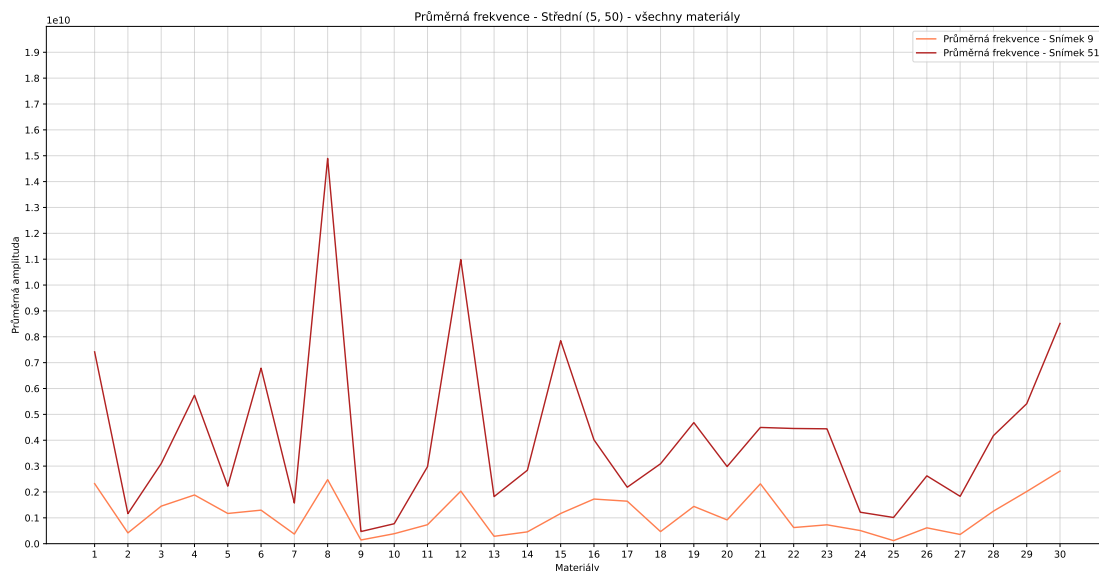


■ **Obrázek 5.10** Průměrná amplituda nízkých frekvencí snímků 9 a 51 přes všechny materiály.



pro materiály 15, 30, které na referenčních snímcích mají velké opakující se prvky ve struktuře. Například materiál 24, který má ve struktuře pouze jemné linie, ale jinak působí jednoduše, má hodnoty vysokých frekvencí téměř nulové. Stejně tak působí jednoduše i materiál 9, který je obecně velmi málo strukturovaný.


Na grafu středních frekvencí (Obr. 5.11) je vidět vysoká amplituda u materiálů 8 a 12, u kte-



**Obrázek 5.11** Průměrná amplituda středních frekvencí snímků 9 a 51 přes všechny materiály.

rých je v odlesku vidět výrazná struktura, která je ale jemnější než u materiálů s vysokými amplitudami nízkých frekvencí. Malé hodnoty zde prokazuje opět málo strukturovaný materiál 9.

Na grafu vysokých frekvencí (Obr. 5.12) je vidět, že více materiálů dosahuje podobně vysokých




**Obrázek 5.12** Průměrná amplituda vysokých frekvencí snímků 9 a 51 přes všechny materiály.

hodnot, není zde již jen pár extrémních. Velká část dřevěných dých má v sobě jemnou strukturu zachycující dřevěná vlákna, je tak pravděpodobné, že více materiálů bude mít vysoké amplitudy vysokých frekvencí.


### 5.1.3 Porovnání histogramů

Porovnání histogramů bylo provedeno na všech hodnotách luminance pro 60 snímků videa a na všech hodnotách luminance jednoho směru BTF dat, konkrétně pro úhel kamery a světla 45 stupňů a všechny azimuty. BTF data jsou zároveň z důvodu výpočetní náročnosti oříznuta na čtverec velikosti 640 okolo středu. Hodnoty obou histogramů jsou normalizované a parametr počet binů je nastaven na 50 (Obr. 5.13).



■ **Obrázek 5.13** Ukázkový graf dvou porovnávaných histogramů.

Histogramy jsou porovnávány pomocí dvou metrik –  $\chi^2$  a *Kolmogorova–Smirnovova odchylka*. V grafu (Obr. 5.14) je možné vidět, že hodnocení je pro většinu materiálů téměř shodné pouze



■ **Obrázek 5.14** Rozdíl histogramů videa a jednoho směru BTF dat podle  $\chi^2$  a *Kolmogorovy–Smirnovovy odchylky*.

s malým posunem, který je u jiných metrik s jiným způsobem výpočtu logický. Důležité je, že


pouze s určitým posunem kopírují své hodnoty, lze tedy výsledky považovat za správné. Pouze pro některé materiály jako 5 či 6 jsou rozdíly mezi metrikami větší.

V našem případě pro metriku  $\chi^2$  hodnota 0 označuje perfektní shodu, hodnota 1 naprostý rozdíl. V grafu se hodnoty pohybují pro většinu materiálů okolo 0,1. Největší rozdíl je poté pro materiál 25, ale i ten drží rozdíl pod 0,3. Celkově jsou tedy hodnoty mnohem blíže 0 než 1, lze tedy říci, že rozdělení hodnot snímků videa dobře pokrývá hodnoty BTF dat pro elevační úhly 45 stupňů. Díky tomu lze říci, že video a tedy i výpočetní statistiky spočítané na něm dobře reprezentují tuto část BTF dat.

U *Kolmogorovy–Smirnovovy odchylky* se materiály pohybují pod hodnotou 0,2. Důležité zde zejména je, že se metriky víceméně shodují, jelikož důležitější metrikou v případě této práce je  $\chi^2$ , které je více vhodné pro diskrétní histogramy.

### 5.1.4 Korelace statistik a PCA analýza


Pro prozkoumání lineární závislosti hodnot statistik mezi sebou je využita analýza jejich korelace. Nejprve jsou spočítány hodnoty průměru výpočetních statistik přes všechny snímky videa a následně je provedena analýza korelace přes všech 30 materiálů. V grafu (Obr. 5.15) je možné



■ **Obrázek 5.15** Korelace výpočetních statistik mezi sebou pro průměrnou hodnotu ze všech snímků videa přes všechny materiály.


vidět, že rozptyl poměrně silně koreluje s hodnotami frekvencí. Silně také koreluje minimum a průměr nebo střední a vysoké frekvence. Minimum a rozptyl naopak korelují záporně, silně záporně korelují také hodnoty šikmosti a špičatosti či minima a rozptylu. U ostatních kombinací nejsou korelace natolik výrazné. Tyto poznatky budou využity později při optimalizaci regrese při mapování výpočetních statistik a vizuálního hodnocení, kdy místo několika korelujících příznaků bude použit pouze jeden.

PCA analýza byla provedena zejména proto, aby ukázala, kolik příznaků je potřeba pro dobrou reprezentaci prostoru tvořeného statistikami. Na singulárních hodnotách sledujeme, zda se v grafu neobjevil skok neboli loket, který by značil výrazný pokles. V grafu (Obr. 5.16) ale



■ **Obrázek 5.16** Singulární hodnoty PCA analýzy.

nic takového ukázáno nebylo, pokles je poměrně stabilní, největší pokles je mezi komponentami 8 a 9, který už ale nebyl tak dramatický na to, aby bylo na jeho základě uvažováno o zmenšení prostoru statistik. Stejnou hranici označil i graf kumulativní sumy vysvětleného rozptylu (Obr. 5.17), kde je vidět, že hodnota 8 se už velmi blíží 1 a tedy, že je vysvětlen téměř celý rozptyl



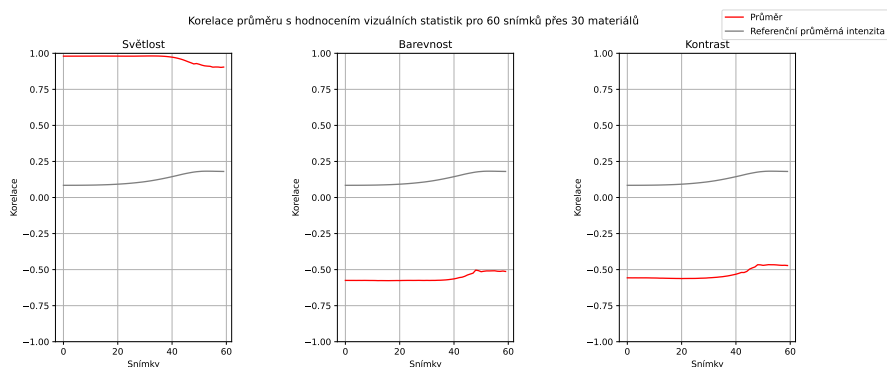
■ **Obrázek 5.17** Kumulativní suma vysvětleného rozptylu jednotlivými PCA komponentami.

hodnot.

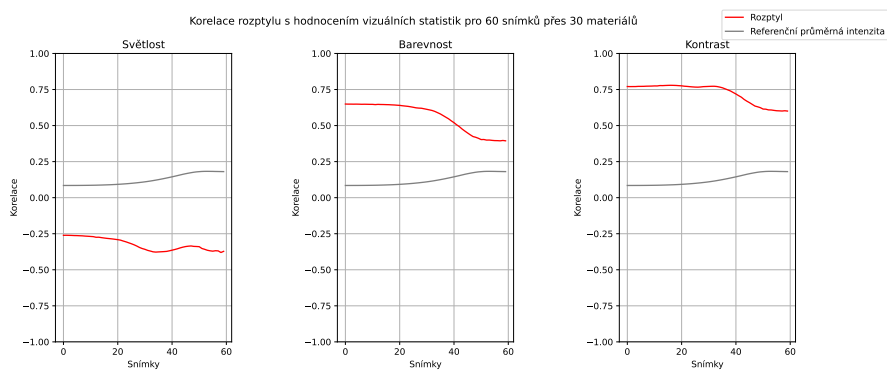
### 5.1.5 Korelace s vizuálními hodnoceními

Tato část analýzy byla reálně provedena až po získání hodnocení vizuálních statistik z psychovizuálních experimentů (3.2). Je analyzována korelace průběhu výpočetních statistik přes 60 snímků s hodnocením vizuálních statistik. Pro ukázkou jsou v grafech ukázány 3 zajímavé vizuální statistiky – *světlost*, *kontrast*, *barevnost*. Korelace všech vizuálních statistik je přiložena v příloze (Obr. A.3, Obr. A.4, Obr. A.5, Obr. A.6). V grafu je zároveň šedě zobrazena přeskálovaná průměrná hodnota luminance přes snímky jako reference průběhu odlesku ve videu.

Zkoumané výpočetní statistiky jsou průměr a rozptyl (Obr. 5.18, Obr. 5.19). Zde je vidět například velká korelace průměru a vizuální statistiky světlosti. Nebo rozptyl, který hodně koreluje s barevností, ale čím více se materiál blíží odlesku, tím více korelace klesá. To potvrzuje domněnku, že zvyšující se hodnoty intenzity v odlesku hůře zaznamenávají barvu materiálu. Zajímavá je korelace rozptylu a kontrastu, která se při přiblížení do odlesku také snižuje, ačkoliv očekávání bylo spíše naopak. Očekávání bylo, že s větším rozptylem hodnot, který se dle Obr.




**■ Obrázek 5.18** Korelace průměru s hodnocením statistik *světlost*, *kontrast*, *barevnost* pro 60 snímků přes všechny materiály.



**■ Obrázek 5.19** Korelace rozptylu s hodnocením statistik *světlost*, *kontrast*, *barevnost* pro 60 snímků přes všechny materiály.

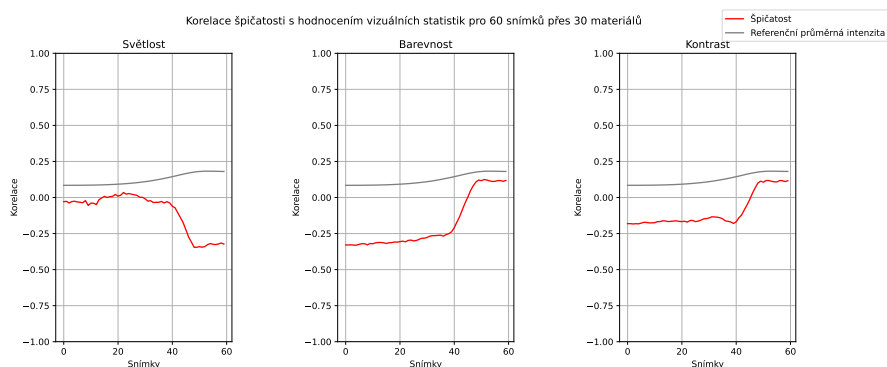
5.7 s větším indexem snímku zvětšuje, se zvýší i kontrast. Snižující se hodnota korelace to ale nenaznačuje.

Dalšími zkoumanými výpočetními statistikami jsou šikmost a špičatost (Obr. 5.20, Obr. 5.21). Zde už je interpretace poměrně složitá, korelace se složitě mění, nemají tak hladký průběh jako



**■ Obrázek 5.20** Korelace šikmosti s hodnocením statistik *světlost*, *kontrast*, *barevnost* pro 60 snímků přes všechny materiály.

u průměru či rozptylu. Stále je ale vidět určitá změna při přechodu do odlesku.



■ **Obrázek 5.21** Korelace špičatosti s hodnocením statistik *světlost*, *kontrast*, *barevnost* pro 60 snímků přes všechny materiály.

## 5.2 Mapování výpočetních statistik na vizuální hodnocení

### 5.2.1 Příprava dat

Před samotným procesem mapování bylo potřeba data předpřipravit.

Nejprve byly spočítány všechny výpočetní statistiky pro všech 60 snímků videa všech 30 materiálů. Pro mapování je ale potřeba jedna hodnota statistiky pro daný materiál, bude tak počítáno s průměrnou hodnotou přes všech 60 snímků, která reprezentuje video jako celek.

Jelikož jsou hodnoty statistik velikostně výrazně odlišné (např. šikmost se pohybuje okolo hodnot 0, ale frekvence se pohybují v řádech milionů) je potřeba hodnoty standardizovat. Byla použita třída knihovny scikit-learn `preprocessing.StandardScaler` [79], která standardizuje data odečtením průměru a vydělením standardní odchylkou („Z-scoring“). Hodnoty se tak dostanou na stejnou škálu a bude možné něco usuzovat z hodnot koeficientů modelů regrese.

Stejně byly statistiky spočítány a standardizovány i pro BTF snímky, které odpovídají snímkům videa. Je to jiná množina snímků než při porovnávání histogramů, kde byl porovnáván celý jeden elevační úhel z BTF dat. Zde se jedná čistě o BTF snímky, které jsou ve stejném intervalu jako snímky videa. Jelikož je samplování BTF dat na hemisféře poměrně řídké, jedná se pouze o 5 snímků. I proto byl pro porovnání histogramů použit celý jeden elevační úhel, jelikož 5 snímků je na zobrazení rozdělení hodnot luminance materiálu příliš málo. Zde ale chceme porovnat mapování přímo pro video a BTF data, byla tak zvolena množina BTF snímků přímo odpovídající videu.

Hodnocení vizuálních vlastností z experimentu bylo pro práci již připraveno vedoucím, stačilo hodnoty načíst ze souboru.

### 5.2.2 Křížová validace

Jelikož v této části výpočtu nebylo k dispozici dostatečné množství dat pro validaci regrese pomocí validační množiny, byla využita křížová validace (2.4.3).

#### 5.2.2.1 Lineární regrese

Jako první model mapování výpočetních statistik (4.1) na vizuální hodnocení (3.2) je použita lineární regrese (2.3.1).


Jelikož lineární regrese nemá žádné důležité hyperparametry, není třeba nic nastavovat a rovnou je možné pustit regresi na standardizovaná data a vizuální hodnocení.

Nejprve je možné zkoumat hodnoty koeficientů, ze kterých lze zaznamenat, jak hodně se daná výpočetní statistika podílí na vysvětlení dané vizuální statistiky.

Bylo zjištěno, že minimum má vysoké záporné koeficienty u komplexnosti, kontrastu, hrubosti a délky linií. Znamená to, že při vysvětlování těchto vizuálních statistik platí záporná korelace s minimem, čím je minimální hodnota vyšší, tím je hodnota statistiky menší. U minima to lze vysvětlit tak, že čím je minimální hodnota intenzity nižší, tím spíše se na povrchu materiálu objevují stíněná místa, povrch je více hrubý, více kontrastní s delšími liniemi. Dále například průměrná hodnota má vysoké koeficienty u světlosti, komplexity a délky linií. Směrnost má velké kladné koeficienty u délky linií a vizuální směrnosti. To je logické, jelikož je to statistika, která linie a celkově směrnost materiálu popisuje. Zajímavé je, že rozptyl má vysoký záporný koeficient u hrubosti, tedy hrubější materiály mají tendenci mít nižší rozptyl hodnot.

Koeficienty lze také studovat ve významu, které výpočetní statistiky nejvíce vysvětlují jednotlivé vizuální vlastnosti. Bylo zjištěno, že světlost je popisována hlavně průměrem, intuitivně pokud má materiál obecně vyšší průměrnou hodnotu intenzity, bude světlejší, ačkoliv by se dalo čekat, že tato statistika bude více korelovat i s maximální hodnotou, což se dle výsledků neděje. Lesklost je kombinována kladnou korelací s minimem a zápornou s průměrem, tedy čím je nejmenší hodnota intenzity větší, ale zároveň průměr nižší, tím je materiál lesklejší. Zajímavé je, že barevnost tolik nekoreluje s výpočetní průměrnou barevností, ačkoliv je to jediná výpočetní statistika počítaná na barevném kanále. Vizuální směrnost má podle očekávání vysoký koeficient u výpočetní směrnosti. Komplexita má velmi nízké koeficienty u minima, ale zase poměrně vysoké u průměru. Kontrast je také nejvíce popisován zápornými koeficienty minima.

Evaluace provedené lineární regrese pomocí metriky R2 křížovou validací (Obr. 5.22) uka-



**Obrázek 5.22** R2 skóre lineární regrese plné množiny výpočetních statistik vysvětlující jednotlivé vizuální statistiky validované pomocí křížové validace.


zuje, že se podařilo velmi dobře zachytit vizuální statistiku světlost. Video data dobře popisují kontrast a BTF data dobře popisují barevnost. Ostatní vizuální statistiky se ale nepodařilo velmi dobře vysvětlit, ostatní hodnocení vysvětleného rozptylu se pohybují pod 0,3. Vizuální statistiky lesklost, pravidelnost a prostorové měřítko se nepovedlo vysvětlit vůbec.

Z evaluace provedené lineární regrese pomocí metriky RMSE křížovou validací (Obr. 5.23) je ale vidět, že i když dle R2 skóre nejsou statistiky velmi dobře vysvětleny, očekávaná chyba modelu se pohybuje okolo 2 až 4 bodů. Jelikož hodnocení vizuálních statistik se pohybuje v rozmezí 1-99, chyba 2 až 4 body není nepřijatelná.

Bylo tedy ukázáno, že výpočetní statistiky do nějaké míry umí vizuální vysvětlit. Použitý model pro vysvětlování lze ale ještě vylepšit.

Jelikož v analýze byla zjištěna kolinearita některých statistik mezi sebou byla nejprve provedena analýza výsledků při vynechání některých ze závislých statistik. Nejdříve byla při regresi vynechána vždy jedna výpočetní statistika a bylo zkoumáno, jak se změnilo validační skóre regrese oproti plné množině statistik. Dobrý vliv mělo vynechání maxima, rozptylu, šikmosti nízkých frekvencí. Špatný vliv mělo vynechání směrnosti, minima či průměru.


Na základě informací z analýzy korelace statistik mezi sebou a této analýzy vynechání vždy




**Obrázek 5.23** RMSE skóre lineární regrese plné množiny výpočetních statistik vysvětlující jednotlivé vizuální statistiky validované pomocí křížové validace.

jedné ze statistik byla provedena evaluace při vybraných kombinacích vynechání určitých výpočetních statistik a byla zkoumána změna validačního skóre oproti použití celé množiny statistik. Bylo upřednostováno zlepšení hodnocení u video dat oproti BTF datům, jelikož hodnoty pro mapování byly získány při experimentu využívajícím právě video data.

Nejlepšího zlepšení u video dat při validaci pomocí R2 skóre (Obr. 5.24) a RMSE skóre (Obr. 5.25) poté dokázala množina statistik minimum, průměr, špičatost, směrovost, vysoké



**Obrázek 5.24** Zlepšení (modré) a zhoršení (červené) R2 skóre při lineární regresi omezené množiny statistik validované pomocí křížové validace.



**Obrázek 5.25** Zlepšení (modré) a zhoršení (červené) RMSE skóre při lineární regresi omezené množiny statistik validované pomocí křížové validace.


frekvence a barevnost. Vynechány tedy byly statistiky maximum, rozptyl, šikmost, nízké a střední frekvence. Vynechání těchto statistik výrazněji pomohlo barevnosti, směrovosti, komplexnosti, kontrastu, pravidelnosti a délce linií. Zhoršily se jen málo výsledky u hrúbosti a lesklosti.



### 5.2.2.2 Hřebenová regrese


Dalším způsobem vylepšení modelu bylo vybráno použití hřebenové regrese (2.3.2). Ta regularizuje hodnoty koeficientů a snižuje tak vliv kolinearit, která byla v analýze mezi některými statistikami zjištěna. Hřebenová regrese používá hyperparametr  $\alpha$  pro určení velikosti regularizace. Nejprve tedy bylo třeba pomocí validace zjistit, který parametr  $\alpha$  pro regularizaci zvolit. V případě této práce je použita pro každou vizuální statistiku jedna regrese, cílem práce je ale vysvětlit všechny zároveň, hodnota alfa byla tedy zvolena podle průměrné hodnoty skóre přes všechny regrese vizuálních statistik.

Pro plnou množinu statistik byla zjištěna nejlepší hodnota  $\alpha$  7,2. V grafu (Obr. 5.26) je



**Obrazek 5.26** R2 skóre hřebenové regrese plné množiny výpočetních statistik vysvětlující jednotlivé vizuální statistiky s nejlepším parametrem alfa přes všechny vizuální statistiky validované pomocí křížové validace.


možné vidět, že se dobře podařilo velmi dobře vysvětlit statistiku světlost, dále poměrně dobře i směrovost, kontrast a délku linií. Naopak se nepodařilo vysvětlit lesklost, komplexnost, hrubost a pravidelnost. Co se ale týče RMSE skóre (Obr. 5.27), to se zlepšilo oproti lineární regresi u sta-




**Obrazek 5.27** RMSE skóre hřebenové regrese plné množiny výpočetních statistik vysvětlující jednotlivé vizuální statistiky s nejlepším parametrem alfa přes všechny vizuální statistiky validované pomocí křížové validace.

tistik lesklost, směrovost, pravidelnost, délka linií a prostorové měřítko. Celkově tedy regularizace zlepšila výsledky hlavně u statistik, které lineární regrese moc dobře nevysvětlovala.

Následně byla analyzována regrese pro omezenou množinu statistik, která nejlépe fungovala u lineární regrese, tedy minimum, průměr, špičatost, směrovost, vysoké frekvence a barevnost. Pro ty byla zjištěna nejlepší hodnota  $\alpha$  0,4 a v grafu (Obr. 5.28) je možné vidět, že zde se dobře podařilo navíc vysvětlit kromě světlosti, směrovosti, kontrastu a délky linií i barevnost. Naopak se vůbec nepodařilo vysvětlit lesklost a hrubost, kde omezený počet statistik validační skóre regrese snížil. Z grafu RMSE skóre (Obr. 5.29) je možné vidět výraznější zlepšení oproti



**Obrázek 5.28** R2 skóre hřebenové regrese omezené množiny výpočetních statistik vysvětlující jednotlivé vizuální statistiky s nejlepším parametrem alfa přes všechny vizuální statistiky validované pomocí křížové validace.



**Obrázek 5.29** RMSE skóre hřebenové regrese omezené množiny výpočetních statistik vysvětlující jednotlivé vizuální statistiky s nejlepším parametrem alfa přes všechny vizuální statistiky validované pomocí křížové validace.

celé množině statistik zejména u vizuálních statistik světlost, pravidelnost a délka linií. U všech ostatních vizuálních statistik také zmenšení množiny skóre lehce zlepšilo.

## 5.2.3 Validace pomocí validační množiny

Kromě experimentu na jedné sadě 30 materiálů byl v průběhu přípravy práce proveden experiment na druhé sadě 30 materiálů. Část této druhé sady tedy poslouží jako testovací množina a část jako validační množina (2.4.2), na které je možné validovat výsledky mapování pomocí regrese. Tento postup do validace přidává nové informace v podobě nových materiálů.


### 5.2.3.1 Lineární regrese

Jako první byla pro mapování výpočetních statistik (4.1) na vizuální hodnocení (3.2) opět použita lineární regrese (2.3.1). Tentokrát byla ale validována pomocí predikce na validační množině modely natrénovanými na trénovací množině.


Jak je možné z grafu skóre R2 (Obr. 5.30) vidět, skóre je mnohem horší než při křížové validaci. Dobře vysvětlena je pouze světlost a barevnost, ostatní statistiky nejsou vysvětlené téměř vůbec nebo vůbec.

I z grafu RMSE (5.31) je vidět velké zhoršení kvality modelů na nových datech oproti křížové validaci. Při hodnocení vizuálních vlastností 1-99 jsou rozdíly 6 až 15 bodů poměrně výrazné.

Bylo opět analyzováno zlepšení skóre při zmenšování množiny výpočetních statistik, ale žádná kombinace validační skóre nijak výrazně nezlepšovala, případně zlepšila některé statistiky ale



**Obrazek 5.30** R2 skóre lineární regrese vysvětlující jednotlivé vizuální statistiky validované pomocí validační množiny.



**Obrazek 5.31** RMSE skóre lineární regrese vysvětlující jednotlivé vizuální statistiky validované pomocí validační množiny.


zhoršila jiné. Bylo tedy rozhodnuto pokračovat ve zlepšování modelu pouze s plnou množinou statistik.

### 5.2.3.2 Hřebenová regrese


Jelikož lineární regrese skončila pro validaci pomocí validační množiny velmi špatně, bylo opět rozhodnuto využít regularizaci koeficientů pomocí hřebenové regrese (2.3.2). Opět byl hledán nejlepší parametr regularizace  $\alpha$ , nejprve přes průměrnou hodnotu skóre přes všechny regrese všech vizuálních statistik.

Nejlepší hodnotou velikosti regularizace  $\alpha$  pro plnou množinu výpočetních statistik s validací pomocí validační množiny byla zjištěna hodnota 35,01. Oproti křížové validaci, kde byly hodnoty 7,2 a 0,4 je to mnohem vyšší číslo a více koresponduje s nalezenou lineární závislostí statistik v analýze. Jak je navíc možné vidět v grafu R2 skóre (Obr. 5.32) regularizace výrazně zlepšila skóre pro velkou část statistik, konkrétně barevnost, směrnost, komplexnost, hrubost, pravidelnost, délka linií i prostorové měřítko, které se nyní pohybují okolo hranice 0,4. Velmi pomohla zejména hrubosti, která ze 0 dostala až na 0,7. I z grafu RMSE (Obr. 5.33) je vidět zlepšení, ačkoliv ne tolik výrazné jako u R2, statistika světlost své skóre dokonce zhoršila. Barevnost, směrnost, komplexnost, kontrast, hrubost, pravidelnost i prostorové měřítko své RMSE díky regularizaci zlepšili. Chyby se stále pohybují okolo 4 až 10, což není úplně ideální, je ale vidět, že regularizace skóre jasně zlepšila.

Místo výpočtu regrese s omezenou množinou statistik byla v této části provedena optimalizace parametru  $\alpha$ . Jelikož každá vizuální statistika má svou regresi se svými koeficienty, je možné parametr  $\alpha$  na regularizaci těchto koeficientů nastavit pro každou regresi jinak. V této části je tedy hledána ideální hodnota regularizace pro každou vizuální statistiku zvlášť. Hodnoty alfa



■ **Obrázek 5.32** R2 skóre hřebenové regrese vysvětlující jednotlivé vizuální statistiky s nejlepším parametrem alfa přes všechny vizuální statistiky validované pomocí validační množiny.



■ **Obrázek 5.33** RMSE skóre hřebenové regrese vysvětlující jednotlivé vizuální statistiky s nejlepším parametrem alfa přes všechny vizuální statistiky validované pomocí validační množiny.


byly hledány z hodnot od 0 do 100 s krokem 0,1. Výsledky jsou popsány v tabulce (Tab. 5.1). U statistik kontrast a pravidelnost vyšla nejvyšší možná hodnota z intervalu a pravděpodobně

■ **Tabulka 5.1** Nejlepší hodnoty hyperparametru  $\alpha$  hřebenové regrese pro různé vizuální dimenze validované pomocí validační množiny

	$\alpha$
Světlost	1,3
Lesklost	20,9
Barevnost	3,5
Směrovost	17,1
Komplexnost	62,3
Kontrast	99,9
Hrubost	62,4
Pravidelnost	99,9
Délka linií	5,5
Prostorové měřítko	22,6

by potřebovali regularizaci mnohem vyšší, vyšší hodnoty  $\alpha$  už ale zkoušeny nebyly.


Jak je možné vidět z výsledného grafu R2 skóre (Obr. 5.34) tato regularizace každé statistiky zvláště pomohla všem statistikám. Na poměrně dobrou vysvětlitelnost se tak dostaly statistiky světlost, barevnost, komplexnost, hrubost a délka linií. Menší kladné skóre potom dosáhly statistiky směrovost, pravidelnost a prostorové měřítko. Kontrast ani lesklost se nepodařilo vysvětlit



**Obrázek 5.34** R2 skóre hřebenové regrese vysvětlující jednotlivé vizuální statistiky s nejlepším parametrem alfa pro každou vizuální statistiku zvlášť validované pomocí validační množiny.

vůbec.

Z grafu RMSE skóre 5.35 je vidět stále rozsah chyby okolo 4 až 10, oproti regularizaci prů-



**Obrázek 5.35** RMSE skóre hřebenové regrese vysvětlující jednotlivé vizuální statistiky s nejlepším parametrem alfa pro každou vizuální statistiku zvlášť validované pomocí validační množiny.


měrnou hodnotou  $\alpha$  se ale skóre lehce zlepšilo a to zejména u světlosti, pravidelnosti a délky linií. Zejména u délky linií, která má přes celé mapování nejhorší RMSE skóre, je zlepšení ze 13 na 11 úspěchem.

## 5.2.4 Výsledek mapování


Jelikož validace pomocí validační množiny přináší nová data a tedy lépe představuje skutečnou generalizaci, bude při vyhodnocování výsledků přihlíženo spíše k této metodě validace. Navíc se lépe shoduje s analýzou o kolinearitě statistik, kde byla zjištěna mezi statistikami závislost a regularizace koeficientů následně vliv závislosti hodně zlepšila. Regularizace u křížové validace nepomohla tolik, jak by bylo očekáváno.

Pro výběr vizuálně podstatných dat tedy bude vybrána celá množina statistik, tedy *maximum, minimum, průměr, rozptyl, šikmost, špičatost, směrnost, nízké, střední a vysoké frekvence a barevnost*. Jako nejlepší model je vybrána hřebenová regrese na celé množině výpočetních statistik s hyperparametry  $\alpha$  nastavenými na zjištěné hodnoty (Tab. 5.1).

Výsledné testovací skóre získané na druhé části druhé sady dat (Obr. 5.36, Obr. 5.37) se kromě světlosti, která je přes celý proces velmi stabilně vysoko, snížilo na hodnoty okolo 0,5. Zajímavé je, že se nepodařilo vůbec vysvětlit směrnost, která při validaci vysvětlená byla a naopak kontrast, který nebyl vůbec vysvětlený při validaci je při testování vysvětlen velmi slušně. Navíc se nepodařilo vysvětlit vůbec délku linií, ale ta má přes celý proces velmi vysoké hodnoty RMSE skóre a tak je očekávatelné, že nebude fungovat úplně správně. RMSE se u většiny



■ **Obrázek 5.36** R2 skóre výsledného vybraného modelu na testovací množině dat.



■ **Obrázek 5.37** RMSE skóre výsledného vybraného modelu na testovací množině dat.

statistik celkově zhoršilo na hodnoty 5 až 10 s délkou linií na hodnotě 17. Zajímavé je, že pro lesklost a kontrast se RMSE výrazně zlepšilo.

Velké rozdíly ve validačním a testovacím skóre (např. u statistiky směrnost či kontrast) může hodně souviset i s velikostí a složením použitých dat. Na trénování bylo použito pouze 30 záznamů na validaci a testování po 15, což je na daný počet atributů málo. Navíc materiály druhé sady dat jsou si navzájem podobné a nejsou moc barevně výrazné s poměrně jednoduchou strukturou.

Pro budoucí výzkum tohoto tématu bude zkoumáno použití jiných, složitějších modelů jako jsou např. neuronové sítě. Hlavním cílem této práce ale bylo zejména zjistit, zda je vysvětlení vizuálních atributů materiálů pomocí výpočetních statistik vůbec možné. Vysvětlení se ukázalo jako možné pro většinu vizuálních statistik, kromě lesklosti a kontrastu. Zkoušení složitějších modelů, ladění parametrů a vylepšování skóre predikce bude součástí dalšího výzkumu.

## 5.3 Výběr vizuálně podstatných dat a komprese dat

V této části jsou použity dva postupy. Jedním je výběr vizuálně podstatných dat (4.3) a komprese dat (4.4) na základě  $\Delta E$  vzdálenosti (2.6.2) jednotlivých snímků. Druhým poté výběr vizuálně podstatných dat (4.3) a komprese dat (4.4) na základě Euklidovské vzdálenosti (2.6.1) výpočetních statistik spočítaných na jednotlivých snímcích.

### 5.3.1 Příprava dat

Výpočet vzdálenostní matice mezi všemi snímky pomocí  $\Delta E$  vzdálenosti všech hodnot pixelů originálních BTF snímků se ukázal jako příliš časově náročný proces. Hlavním problémem je zejména množství dat. Při porovnávání originálních snímků BTF dat je třeba u každého materiálu porovnat přes 2 miliony hodnot. Bylo tedy třeba si předpřipravit BTF snímky v menší velikosti

tak, aby výpočet skončil v rozumném čase. Navíc originální snímky jsou uloženy ve formátu EXR v barevném prostoru XYZ, což je formát, který se při načítání do programovacího jazyku Python zdlohouvě převádí do formátu pole hodnot v LAB barevném prostoru, který je použit při výpočtu. Bylo by možné předpřipravit snímky pouze do RGB prostoru, jelikož výpočet LAB z RGB je již jednoduchý, ale vzhledem k časové náročnosti celého procesu bylo rozhodnuto o uložení přímo v LAB prostoru.

Snímky tak byly předpřipraveny v barevném prostoru LAB ve velikosti 256x256 pixelů a to tak, že se nejprve snímek ořízl na velikost 512x512 a následně byl uložen každý druhý pixel. I pro takto zmenšená data ale stále výpočet pro jeden materiál neskončil do 3 hodin, snímky tedy byly už přímo během výpočtu oříznuty až na velikost 100x100 pixelů. Po této úpravě již trval výpočet vzdálenostní matice pro jeden materiál pouze okolo 1 hodiny.


Pro výpočet vzdálenostní matice *Euklidovské vzdálenosti výpočetních statistik* snímků BTF dat bylo nejprve potřeba statistiky spočítat a uložit. Statistiky byly počítány na BTF datech, která byla upravena pro metodu výpočtu pomocí  $\Delta E$  metriky, tedy na snímcích velikosti 256x256. Jelikož je pro výpočet průměrné barevnosti potřeba znát kanál chromy, byly snímky nejprve převedeny do barevného prostoru LCH. Výpočet na upravených BTF datech místo originálních byl zvolen zejména pro vhodnější porovnání obou metod. Při výpočtu metodou  $\Delta E$  metriky bylo nakonec třeba snímky zmenšit až na 100x100, to se ale v této metodě pomocí Euklidovské vzdálenosti výpočetních statistik již neprovádělo, tedy oba postupy nakonec pracují s lehce odlišnými daty.

### 5.3.2 Analýza vzdálenostních matic a prahů vzdálenosti

Nejprve byly spočítány a uloženy vzdálenostní matice všech snímků obou typů vzdálenosti pro všechny materiály. Proces výpočtu matic  $\Delta E$  byl hodně časově náročný oproti Euklidovské vzdálenosti výpočetních statistik, které výpočet jedné vzdálenostní matice trval pár minut.

Poté následoval samotný výběr vizuálně důležitých dat. Nejprve byl analyzován samotný vztah prahů vzdálenosti a ponechaného počtu snímků. Jako první byl analyzován jeden materiál pro získání reference, které rozmezí prahů vzdálenosti odpovídá nahrazení žádného a naopak všech snímků.


Pro metodu  $\Delta E$  vzdálenosti snímků je vidět, že v grafu (Obr. 5.38) že se toto rozmezí pohy-



■ **Obrázek 5.38** Poměr počtu nahrazených snímků a prahu  $\Delta E$  vzdálenosti snímků pro materiál 1.

buje přibližně mezi prahy 1 až 10.


Pro metodu Euklidovské vzdálenosti výpočetních statistik je vidět v grafu 5.39. rozmezí



■ **Obrázek 5.39** Poměr počtu nahrazených snímků a prahu Euklidovské vzdálenosti výpočetních statistik pro materiál 1.

přibližně mezi prahy 0 a 2.

Následně byl spočítán tento poměr mezi počtem nahrazených snímků a prahem vzdálenosti pro všechny materiály. Na tomto grafu pro metodu  $\Delta E$  vzdálenosti snímků (Obr. 5.40) je vidět




■ **Obrázek 5.40** Poměr počtu nahrazených snímků a prahu  $\Delta E$  vzdálenosti snímků pro všechny materiály.



fakt stanovený v práci [66], že redukce závisí na typu materiálu. Zde je vidět, že každý materiál má jiný průběh poměru nahrazených snímků a prahu vzdálenosti. Například materiál 9 je při prahu velikosti 3 redukován na počet snímků přibližně 1500. Naopak materiál 1 při prahu velikosti 3 je redukován na počet snímků okolo 5500. Pokud tedy požadujeme redukci na základě velikosti dat, tedy počtu snímků, je třeba pro každý materiál hledat správný práh vzdálenosti zvlášť.

Taky to poukazuje na to, že různé materiály mají různě výrazné odlišnosti snímků s jiným nastavením kamery a světla. Některé materiály mají při změně podmínek pouze malé rozdíly (jako například materiál 9) a tak je si velký počet snímků blízký. Některé materiály mají při změně podmínek rozdíly větší (jako například materiál 1) a velký počet snímků je od sebe velmi vzdálený. Je možné si všimnout i na referenčních snímcích mimo odlesk (Obr. 5.2) a v odlesku (Obr. 5.3), že materiál 1 vypadá velmi rozdílně v odlesku a mimo něj a materiál 9 vypadá na obou snímcích téměř stejně.

V grafu pro metodu Euklidovské vzdálenosti výpočetních statistik (Obr. 5.41) je vidět větší



■ **Obrázek 5.41** Poměr počtu nahrazených snímků a prahu Euklidovské vzdálenosti výpočetních statistik pro všechny materiály.

jednotnost ve tvaru průběhu mezi jednotlivými materiály. Hodnoty prahů jednotlivých materiálů pro stejný počet ponechaných snímků jsou si mnohem blíže než u předchozí metody, stále jsou ale poměrně daleko od sebe. To je vidět, pokud prozkoumáme například materiál 25, který při prahu 0,5 redukuje počet snímků o 4500. Oproti tomu například materiál 7 při tom samém prahu redukuje počet snímků pouze o 1500.


### 5.3.3 Výběr dat a komprese

Uměle byly zvoleny 3 prahy počtu snímků – 2000, 100 a 10. Tyto počty nebyly dodrženy vždy naprosto přesně, přesnost prahu byla zvolena na 2 desetinná místa a v některých případech bylo při jednom kroku zvýšení hodnoty prahu nahrazeno více snímků. Pro dodržení přesného počtu snímků při redukcí by bylo třeba zvolit práh s větším počtem desetinných míst. Zároveň

byly vybrány materiály s indexy 1, 2 a 3 (Obr. 5.2, Obr. 5.3), u kterých bude proveden výběr důležitých dat, komprese a následná vizualizace objektu s redukovanou množinou snímků.

Pro materiály byla vytvořena vizualizace pozic ponechaných snímků. Zleva doprava se ve vizualizaci zvyšuje index pozice kamery, seshora dolů se ve vizualizaci zvyšuje index pozice světla. Zvyšující se intenzita pozadí z černé na šedou naznačuje přechod do odlesku. Střídání tmavých a světlých pruhů indikuje jednotlivé elevace směru pohledu a směru osvětlení. Ponechané snímky jsou poté označeny zelenou barvou.


Vizualizace pro  $\Delta E$  (Obr. 5.42) ukazuje, že důležité snímky kopírují pozice odlesků, snímky



■ **Obrázek 5.42** Mapa ponechaných snímků pro různé prahy vzdálenosti  $\Delta E$  materiálu 1. Obrázek poskytl vedoucí práce.

v odlesku jsou tedy pravděpodobně důležitější než snímky mimo odlesk. Pro materiály 2 a 3 je mapa přiložena v příloze (Obr. A.7, Obr. A.9).

Vizualizace pro Euklidovskou vzdálenost výpočetních statistik (Obr. 5.43) na rozdíl od  $\Delta E$



■ **Obrázek 5.43** Mapa ponechaných snímků pro různé prahy Euklidovské vzdálenosti výpočetních statistik materiálu 1. Obrázek poskytl vedoucí práce.

metody nekopíruje tolik ponechanými snímky směr odlesků a celkově není rozpoznatelný žádný jasný vzor pro ponechání snímků. Oproti  $\Delta E$  je zde vidět preference nulové elevace světla u různých elevací kamery. Pro materiály 2 a 3 je mapa přiložena v příloze (Obr. A.8, Obr. A.10).

Obecně obě metody vždy ponechávají snímek s prvním indexem pozice kamery a prvním indexem pozice světla. Je to takto úmyslně definováno již v rámci implementace obou metod. Je to proto, že při focení tohoto snímku je kamera stejně jako světlo přímo nad plochou materiálu a nevzniká zde žádná deformace či rozmazání. Je to tedy velmi důležitý snímek s nezkreslenou informací o materiálu, je tedy vždy ponecháván. Zároveň je možné vidět, že obecně jsou často vybrány snímky s prvním indexem pozice světla (tedy na levém okraji vizualizace), ve kterém je světlo přímo nad materiálem.

Následně byly spočítány matice nahrazených indexů. Důležitou poznámkou k výpočtu těchto matic je to, že při implementaci v této práci byl použit postup, kdy při procházení snímků a hledání vyšších indexů pozice (vyšších hodnot elevací kamery a světla), které by zkoumaný

snímek nahradil, jsou vždy nahrazeny všechny odpovídající snímky, i ty, které už byly jednou nahrazeny. Snímky s vyššími elevacemi jsou tak nahrazeny prvním ponechaným snímkem s nižší elevací.

Takto vytvořené matice indexů mohou být dále použity pro vizualizaci materiálu reprezentovaného omezenou množinou BTF snímků. Při požadovaném úhlu osvětlení a úhlu pohledu lze v matici najít index snímku, který při těchto podmínkách použít. Ponechané snímky mají na své pozici v matici svůj index, nahrazené snímky mají na své pozici v matici index některého z nahrazených snímků.

Pomocí představených postupů lze tak pro jakýkoliv materiál reprezentovaný pomocí BTF vytvořit vzdálenostní matici najít práh vzdálenosti pro požadovanou velikost redukce, vytvořit s daným prahem matici nahrazených indexů a omezit tak počet potřebných BTF snímků pro vizualizaci.



# Analýza výsledků

*Závěrečná kapitola hodnotící kvalitu výsledků praktické části a analyzující možnost dalšího postupu v budoucím výzkumu tématu.*

## 6.1 Validace aplikace statistik

Pro účely ohodnocení kvality redukce a komprese byly vytvořeny 3D vizualizace objektů mapovaných materiálem reprezentovaným pomocí BTF. Byla vytvořena vizualizace objektu mapovaného plnými daty a poté vizualizace objektu mapovaného daty, kde jsou snímky redukovány na množinu podle matice nahrazených indexů. Pro porovnání kvality úrovně velikosti redukce byly vytvořeny také různé verze vizualizace pro různé prahy vzdálenosti.

Jelikož zobrazený obrázek objektu pokrývá pouze část dat s určitými nastaveními pozice kamery a pozice světla, byly vytvořeny vizualizace také pro dvě různá nastavení pozic kamery a pozic světla. První pozice má elevaci kamery  $45^\circ$  a elevaci světla  $53^\circ$ . Světlo je posunuté od kamery o azimut  $112$ , materiál je tak osvětlen zprava a zezadu oproti kameře. Druhá pozice má elevaci kamery  $53^\circ$  a elevaci světla  $37^\circ$ . Světlo je posunuté od kamery o azimut  $13$ , materiál je tedy osvětlen z téměř stejného směru, který snímá kamera.

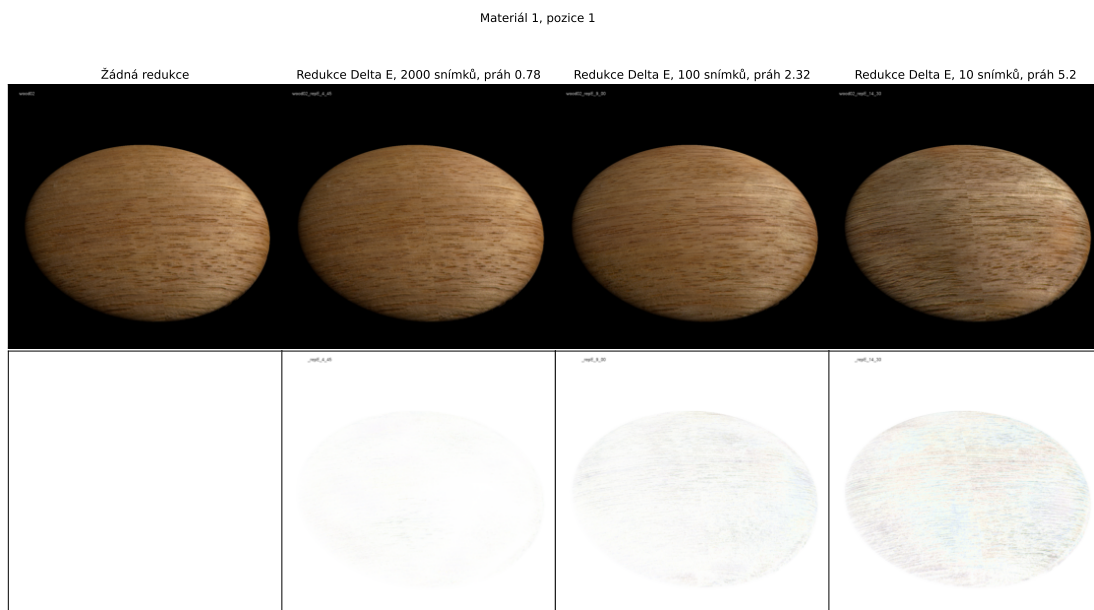
Bude zkoumána kvalita vizualizací s redukovanou množinou dat oproti vizualizaci s plnou množinou dat. Vizualizace byly dodány vedoucím práce na základě vypočítané matice nahrazených indexů pro daný materiál a počet snímků.

### 6.1.1 Vizualní porovnání

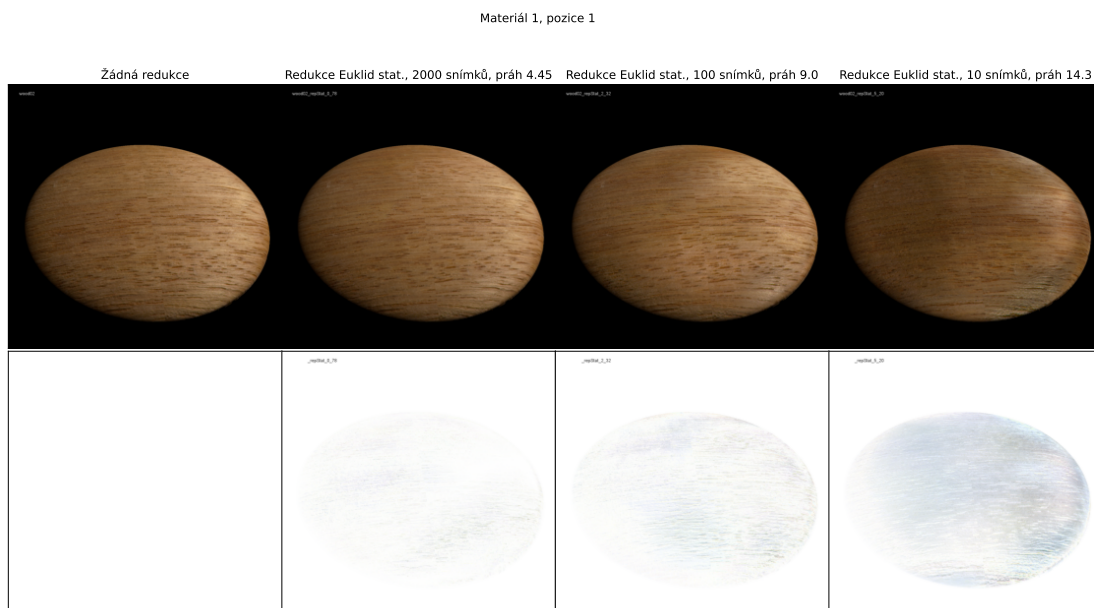
V této části jsou subjektivním lidským viděním ohodnoceny vizualizace pro různé prahy vzdálenosti. V grafu vizualizací je vždy vlevo vizualizace s plnými daty a postupně směrem doprava se zvyšuje množství redukce dat postupně na 2000, 100 a 10 snímků. Pro jednodušší ohodnocení velikosti vizuální chyby jsou pod samotnými obrázky objektů jsou připraveny rozdílové snímky oproti vizualizaci s plnými daty.

První je ukázána vizualizace materiálu 1 v pozici 1 pro redukci pomocí různých prahů nahrazení snímků  $\Delta E$  metriky (Obr. 6.1) a pro porovnání vizualizace materiálu 1 v pozici 1 pro redukci pomocí různých prahů nahrazení snímků Euklidovské vzdálenosti výpočetních statistik (Obr. 6.2).

Z vizualizací i rozdílových snímků je zřejmé, že jak  $\Delta E$ , tak Euklidovská vzdálenost statistik při větším počtu ponechaných snímků (jako zde 2000) velmi dobře zachovávají strukturální i barevnou informaci materiálu.



■ **Obrázek 6.1** Vizualizace materiálu 1 z pozice 1 pro plná data a poté pro různé hodnoty ponechaných snímků (práhů) společně s rozdílovými snímky oproti plným datům, redukce dat pomocí  $\Delta E$  metriky. Obrázek poskytl vedoucí práce.



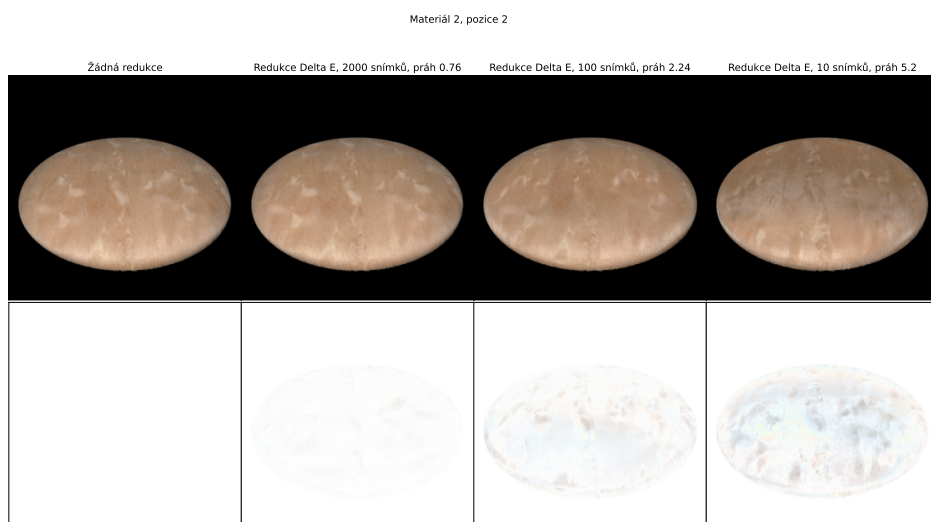
■ **Obrázek 6.2** Vizualizace materiálu 1 z pozice 1 pro plná data a poté pro různé hodnoty ponechaných snímků (práhů) společně s rozdílovými snímky oproti plným datům, redukce dat pomocí Euklidovské vzdálenosti statistik. Obrázek poskytl vedoucí práce.

Při zmenšení počtu snímků na 100  $\Delta E$  metrika stále ztrácí pouze malé množství celkové informace. Oproti tomu Euklidovská vzdálenost výpočetních statistik ztrácí informaci o povrchové struktuře, materiál vypadá plošší a lze pozorovat v některých místech naštědlé či příliš tmavé

zabarvení.

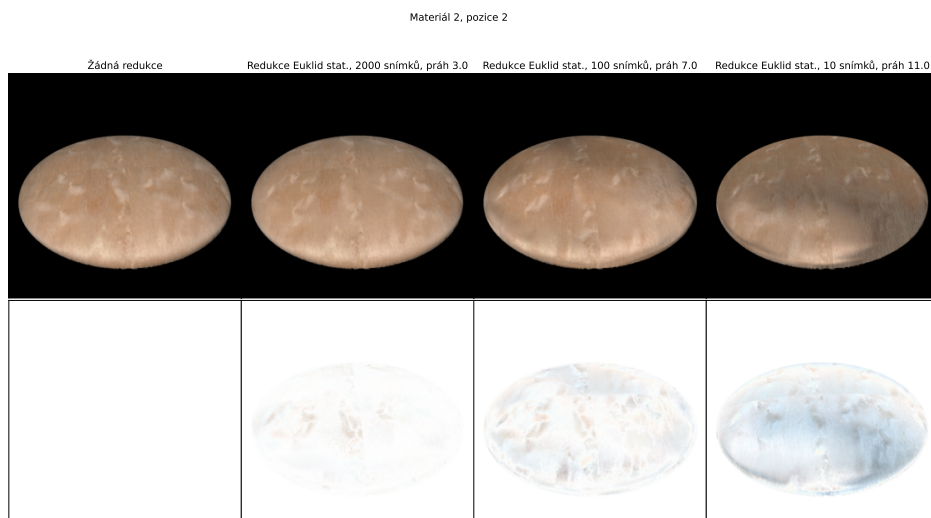
Pro velmi malý počet snímků (jako zde 10) lépe zachovává strukturu dat  $\Delta E$  metrika, pouze se ztratila informace o barvě, materiál zešedl, vybledl a změnil tvar odlesku. Vizualizace s Euklidovskou vzdáleností statistik pro takto malá data vypadá mnohem tmavší než by měla být i barevně odlišná, odlesk je pouze lehce viditelný, struktura se ztrácí.

Pro ukázkou druhé použité pozice je ukázána vizualizace materiálu 2 v pozici 2 pro redukci pomocí různých prahů nahrazení snímků  $\Delta E$  metriky (Obr. 6.3) a pro redukci pomocí různých



■ **Obrázek 6.3** Vizualizace materiálu 2 z pozice 2 pro plná data a poté pro různé hodnoty ponechaných snímků (prahů) společně s rozdílovými snímky oproti plným datům, redukce dat pomocí  $\Delta E$  metriky. Obrázek poskytl vedoucí práce.

prahů nahrazení snímků Euklidovské vzdálenosti výpočetních statistik (Obr. 6.4).



■ **Obrázek 6.4** Vizualizace materiálu 2 z pozice 2 pro plná data a poté pro různé hodnoty ponechaných snímků (prahů) společně s rozdílovými snímky oproti plným datům, redukce dat pomocí Euklidovské vzdálenosti statistik. Obrázek poskytl vedoucí práce.

Redukce pomocí  $\Delta E$  opět poměrně dobře zachovala strukturu materiálu i barevnou informaci.

Materiál začíná vypadat velmi odlišně až při redukci na 10 snímků. Při tom opět ztrácí barvu a část informací o struktuře povrchu.

Opět je možné vidět, že při redukci pomocí výpočetních statistik se postupně ztrácí informace o struktuře. Metrika má problém se zachováním informací o větších prvcích vzoru materiálu. Materiál se opět při snižování počtu snímku jeví více tmavší, informace o odlesku je zachována pouze v místě přímého osvětlení.

Vizualizace dalších kombinací materiálu a pozice je možné najít v příloze (Obr. A.11, Obr. A.12, Obr. A.13, Obr. A.14, Obr. A.15, Obr. A.16, Obr. A.17, Obr. A.18).

### 6.1.2 Práh vzdálenosti

Při použití metody využívající  $\Delta E$  vzdálenost odpovídají ponechání požadovaného počtu snímků prahové hodnoty vzdálenosti zaznamenané v tabulce (Tab. 6.1).

■ **Tabulka 6.1** Prahy vzdálenosti snímků  $\Delta E$  pro vybrané materiály a vybraný počet ponechaných snímků

	2000 snímků	100 snímků	10 snímků
<b>Materiál 1</b>	4,45	9,00	14,30
<b>Materiál 2</b>	3,00	7,00	11,00
<b>Materiál 3</b>	2,91	6,52	11,70

Podle stupnice zavedené v teorii, by hodnota 1 měla znamenat hranici lidským okem rozpoznatelného rozdílu. Zde se ale při redukci na 2000 snímků hodnoty prahu pohybují okolo 3 až 4. Z analýzy vizuálního porovnání redukce a rozdílových snímků vizualizace redukce oproti vizualizaci plných dat je ale vidět, že redukce na 2000 snímků se od plných dat téměř neliší.

Při použití metody využívající Euklidovskou vzdálenost výpočetních statistik odpovídají ponechání požadovaného počtu snímků prahové hodnoty vzdálenosti zaznamenané v tabulce (Tab. 6.2).

■ **Tabulka 6.2** Prahy vzdálenosti snímků Euklidovské vzdálenosti výpočetních statistik pro vybrané materiály a vybraný počet ponechaných snímků

	2000 snímků	100 snímků	10 snímků
<b>Materiál 1</b>	0,78	2,32	5,20
<b>Materiál 2</b>	0,76	2,24	5,20
<b>Materiál 3</b>	0,89	2,70	5,90

Jak bylo zaznamenáno již při analýze vzdálenostních matic a prahů vzdálenosti (5.3.2) hodnoty prahů Euklidovské vzdálenosti jsou si mezi jednotlivými materiály pro daný počet snímků mnohem bližší než hodnoty pro  $\Delta E$ . Rozptyl hodnot pro jednotlivé počty snímků je u  $\Delta E$  vyšší. U Euklidovské vzdálenosti výpočetních statistik se tak snáze zjistí správná hodnota prahu při redukci více různých materiálů se stejným požadovaným počtem snímků.


### 6.1.3 Porovnání histogramů

Pro ohodnocení zachovávání rozdělení hodnot pixelů snímku po redukci bylo na snímcích vizualizace provedeno porovnání rozdělení hodnot intenzity pomocí porovnání histogramů. Vizualizace nepokrývá celý obrázek a zvolené pozadí má černou barvu s hodnotou intenzity 0. Pro omezení




vlivu hodnot pozadí na výpočet vzdálenosti histogramů byly hodnoty intenzity omezeny na hodnoty větší než 0. Materiály v experimentu nejsou natolik tmavé, aby hodnota 0 byla i na místě samotného objektu vizualizace.

Porovnání pro redukci na 100 snímků bylo provedeno pro metriku  $\Delta E$  (Obr. 6.5) i pro metriku Euklidovské vzdálenosti výpočetních statistik (Obr. 6.6)



■ **Obrázek 6.5** Histogram hodnot intenzity vizualizace s plnými daty a s redukovánými daty bez hodnot pozadí vizualizace pro materiál 1 v pozici 1 pro  $\Delta E$ .



■ **Obrázek 6.6** Histogram hodnot intenzity vizualizace s plnými daty a s redukovánými daty bez hodnot pozadí vizualizace pro materiál 1 v pozici 1 pro Euklidovskou vzdálenost výpočetních statistik.

Jako hlavní metrika vzdálenosti byla zvolena  $\chi^2$  metrika, která je vhodná pro porovnání diskrétních histogramů. Její hodnoty pro různé vizualizace jsou zaznamenány v tabulce (Tab. 6.3). Je například vidět, že pro redukci na 2000 i na 100 jsou hodnoty stále zachovávány velmi dobře u obou metod redukce snímků. Vzdálenost se pohybuje v tisícinách či setinách. Při větší redukci pouze na 10 snímků si  $\Delta E$  stále zachovává poměrně dobré pokrytí hodnot s rozdíly pod 0,2. Naopak redukce pomocí Euklidovské vzdálenosti výpočetních statistik při takto velké redukci zvyšuje rozdíl histogramů hodnot na hodnoty okolo 0,5, což již není akceptovatelný výsledek.

Zajímavé také je, že druhá pozice s osvětlením materiálu ze směru kamery při redukci mnohem hůře zachovává hodnoty. Vzdálenosti histogramů jsou často i o řád výše. Z toho vyplývá, že kvalita

■ **Tabulka 6.3**  $\chi^2$  vzdálenosti histogramů luminance snímků materiálu s plnou a s omezenou množinou dat

$\chi^2$	2000 $\Delta E$	2000 Euklid Stat.	100 $\Delta E$	100 Euklid Stat.	10 $\Delta E$	10 Euklid Stat.
<b>Pozice 1 Materiál 1</b>	0,001	0,003	0,004	0,008	0,021	0,334
<b>Pozice 1 Materiál 2</b>	0,003	0,006	0,010	0,056	0,081	0,255
<b>Pozice 1 Materiál 3</b>	0,001	0,001	0,007	0,050	0,056	0,448
<b>Pozice 2 Materiál 1</b>	0,003	0,012	0,020	0,044	0,095	0,637
<b>Pozice 2 Materiál 2</b>	0,003	0,008	0,039	0,098	0,166	0,695
<b>Pozice 2 Materiál 3</b>	0,002	0,003	0,079	0,037	0,177	0,760

redukce také závisí na úhlu pohledu a úhlu osvětlení výsledku.

Jelikož Kolmogorova-Smirnovova odchylka je vhodná spíše pro spojitě funkce než histogramy a v práci je použita hlavně pro porovnání ohodnocení obou metrik, je tabulka jejich hodnot přiložena v příloze (Tab. A.1).

## 6.2 Závěrečné vyhodnocení použitých metod komprese

První metoda redukce pomocí  $\Delta E$  vzdálenosti snímků velmi dobře zachovává původní chování materiálu i při větší redukci až na desítky snímků. Vizually materiál vypadá velmi podobně z velké části jen ztrácí informaci o barvě. Dobře zachovává i samotné rozdělení hodnot intenzity.

Co je ale velká nevýhoda této metody je výpočetní náročnost. Výpočet pro jeden materiál i pro hodně zmenšená vzorová data trval v řádu hodin. Zmíněná velká kvalita redukce je postavena na porovnávání všech hodnot pixelů všech snímků zdrojových dat, což je obrovské množství. Zároveň neposkytuje žádné informace o materiálu navíc.

Hodí se tedy pro účely, kdy je potřeba velká redukce a nezáleží tolik na časové náročnosti výpočtu.

Druhá metoda redukce pomocí *Euklidovské vzdálenosti výpočetních statistik* velmi dobře zachovává původní chování materiálu při redukci na stovky snímků, což při redukci z 6561 snímků je stále velmi dobrý výsledek. Při větší redukci už se informace o materiálu ztrácí. Stejně tak zachovává i rozdělení hodnot pixelů. Při redukci na stovky snímků zachovává informace stejně dobře jako první metoda, při velké redukci hodně mění rozdělení hodnot.

Velkou výhodou druhé metody oproti první je výpočetní a časová náročnost. Výpočet hodnot statistik na zdrojových datech zabere desítky minut, ale samotný výpočet vzdálenostní matice je hotov v řádu jednotek minut. To je velké zlepšení oproti první metodě, kde příprava dat zabere desítky minut a výpočet hodiny. Navíc je spočítána sada 11 hodnot, která každý snímek materiálu charakterizuje a lze ji využít i pro jiné účely jako byla například zmíněná kategorizace, predikce vlastností materiálu apod.

Hodí se tedy pro účely, kdy není třeba příliš velká redukce, stačí redukce na stovky snímků. Zároveň ji lze využít v případě, kdy je omezen čas na dokončení výpočtu, jelikož je mnohem rychlejší při zachování dostatečné kvality pro menší redukce.

### 6.3 Další plánovaný výzkum

Na výzkum představený v této práci lze navázat v několika směrech.

Jednou věcí, kterou lze vylepšit je predikce vizuálních hodnocení vlastností materiálů pomocí výpočetních statistik. Lze zlepšit výběr výpočetních statistik např. průměrná barevnost pouze ohodnocuje jak moc je materiál barevný, přidání statistiky popisující odstín barvy materiálu by mohlo pomoci s popisem barevné informace materiálu. Zvolení a trénování složitějších modelů by také mohlo zlepšit zejména schopnost generalizace modelu na jiné typy materiálů než jsou dřevěné dýhy. Problémem bylo také malé množství trénovacích, validačních a testovacích dat, provedení více experimentů a získání více vizuálních hodnocení více materiálů by mohlo také pomoci se zlepšením predikce.

Zajímavé by také bylo více prozkoumat použití dynamických dat jako právě video, které lépe ukazuje všechny vlastnosti materiálu za různých podmínek při experimentech, které nejsou prováděny na fyzických vzorcích. V této práci jsou hodnoty jednotlivých snímků pouze zprůměrovány do jedné hodnoty charakterizující celé video a ztrácí se tak vlastnost videa ukázat větší množství informací o materiálu. Případně lze použít jinou metriku na sjednocení hodnot než je průměr.

Další velkou částí, kterou lze zlepšit je samotný výpočet vzdáleností při redukci snímků. Například použití jiných metrik pro výpočet vzdálenosti výpočetních statistik. V souvislém výzkumu se ukázalo, že použití korelace místo Euklidovské vzdálenosti výrazně pomohlo zlepšit výsledky redukce a kategorizace materiálů.



## Závěr

Cíle teoretické části práce byly splněny v první části, kde byly představeny a porovnány metody reprezentace vzhledu materiálů, následně popsány různé metody strojového učení pro zachycení vizuálních charakteristik jako jsou pravděpodobnostní modely, metody lineární dekompozice, odrazivostní modely pracující po pixelech či metody hlubokého učení. Byly analyzovány i práce věnující se lidskému vnímání materiálu a to jak ve formě fotografií, tak fyzických objektů.

Prvním cílem praktické části práce byl výběr a analýza množiny definovaných výpočetních statistik a jejich mapování na hodnocení vizuálních vlastností materiálu.

Jako vhodná množina byla zvolena množina statistik *maximum*, *minimum*, *průměr*, *rozptyl*, *šikmost*, *špičatost*, *směrnost*, *nízké*, *střední a vysoké frekvence* vypočítaných z hodnot luminance snímku. Pro zachycení barevné informace byla přidána statistika *průměrná barevnost* získaná z hodnot chromy snímku. Statistiky byly definovány v teoretické části a byl analyzován jejich průběh na datech videa, jejich korelace mezi sebou i s vizuálními hodnoceními.

Následně bylo provedeno mapování výpočetních statistik na hodnocení vizuálních statistik pomocí lineární a hřebenové regrese. Nejlepším modelem pro mapování se dle  $R^2$  a RMSE skóre ukázala hřebenová regrese na plné množině statistik s hyperparametrem  $\alpha$  optimalizovaným pro každou vizuální statistiku zvlášť. Podařilo se dosáhnout dobrého testovacího skóre na většině vizuálních statistik, některé se nepodařilo dobře vysvětlit pravděpodobně kvůli malému množství dat, velké kolinearitě statistik a malé různorodosti testovací sady materiálů. Očekávanou chybu predikce na nových datech měřenou pomocí RMSE se ale podařilo udržet na hodnotách okolo 5 až 10 pro interval hodnocení 1 až 99.


Druhým cílem praktické části práce bylo poté nalezení vizuálně důležité podmnožiny BTF dat a její využití pro kompresi zachovávající vizuální vlastnosti materiálu. V této části byl porovnán standardní postup redukce pomocí metriky  $\Delta E$  a postup využívající Euklidovskou vzdálenost vybraných výpočetních statistik navržených v první části práce. Reprezentace materiálu pomocí komprimované množiny dat pro různé prahy zvolených metrik byly ohodnoceny pomocí definovaných sledovaných statistik. Hodnocena byla vizuální stránka, práh dané metriky a vzdálenost histogramu hodnot oproti reprezentaci plnou množinou dat.

Postup pomocí  $\Delta E$  vzdálenosti snímků BTF modelu se ukázal jako velmi výpočetně náročný s časem výpočtu v řádu hodin. Metoda ale umožňuje redukcí až na desítky snímků při dobrém zachování vizuálních vlastností.


Postup pomocí výpočtu Euklidovské vzdálenosti v práci navržených výpočetních statistik na snímcích BTF materiálu se pohyboval se v řádu desítek minut. Byl tedy mnohem méně časově náročný, než první metoda. Euklidovská vzdálenost výpočetních statistik podle sledovaných statistik velmi dobře zachovává vizuální vlastnosti materiálu při redukcí až na stovky materiálů, při redukcí na desítky snímků kvalita redukce klesá. Celkově ale metoda ukázala, že vybrané výpočetní statistiky dobře reprezentují vizuální vlastnosti materiálu a mohou tak být využity jako slibný základ dalšího výzkumu v oblasti reprezentace vzhledu materiálu.



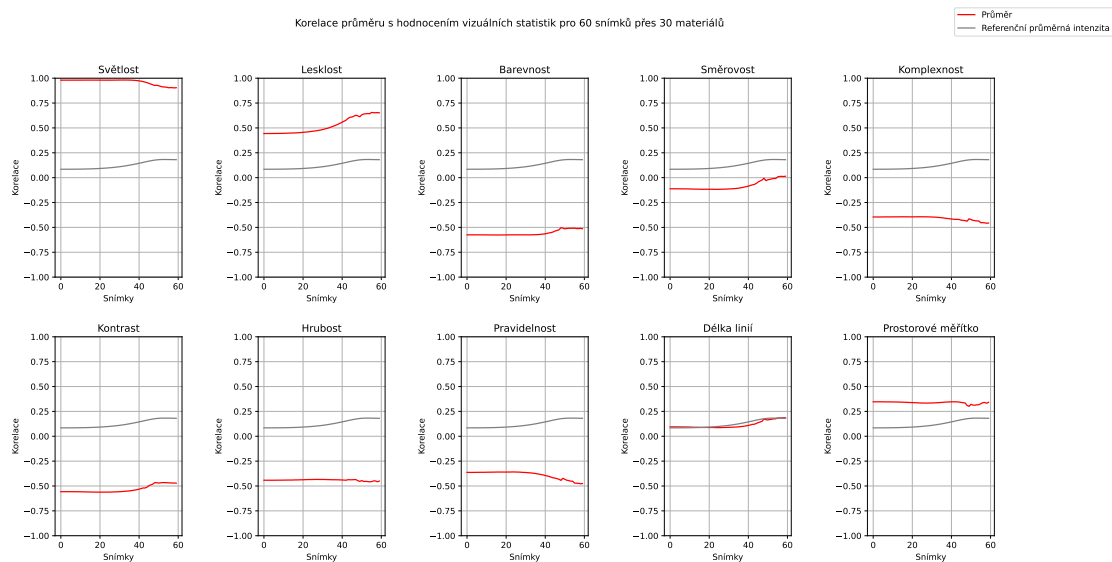
Příloha A  
Příloha



■ Obrázek A.1 Průběh hodnoty šikmosti přes 60 snímků pro 30 materiálů.

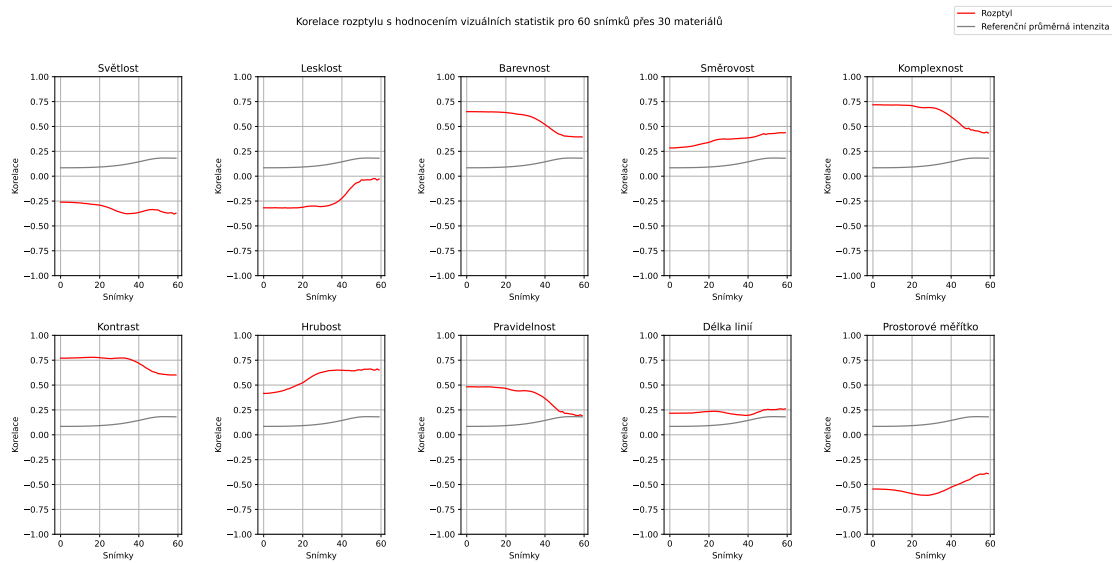


■ Obrázek A.2 Průběh hodnoty špičatosti přes 60 snímků pro 30 materiálů.

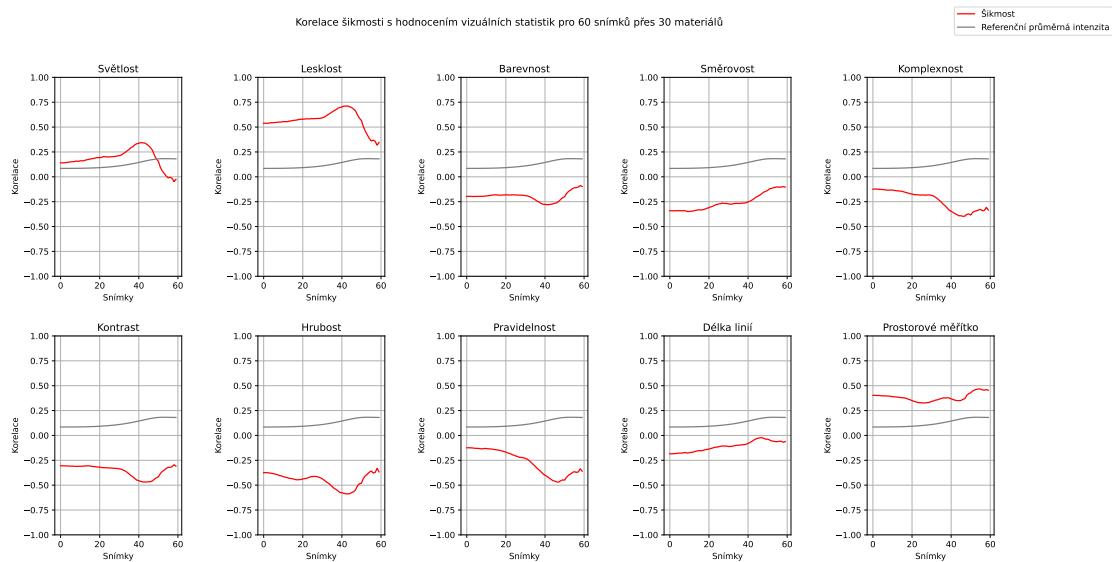


■ Obrázek A.3 Korelace průměru s hodnocením všech vizuálních statistik pro 60 snímků přes všechny materiály.

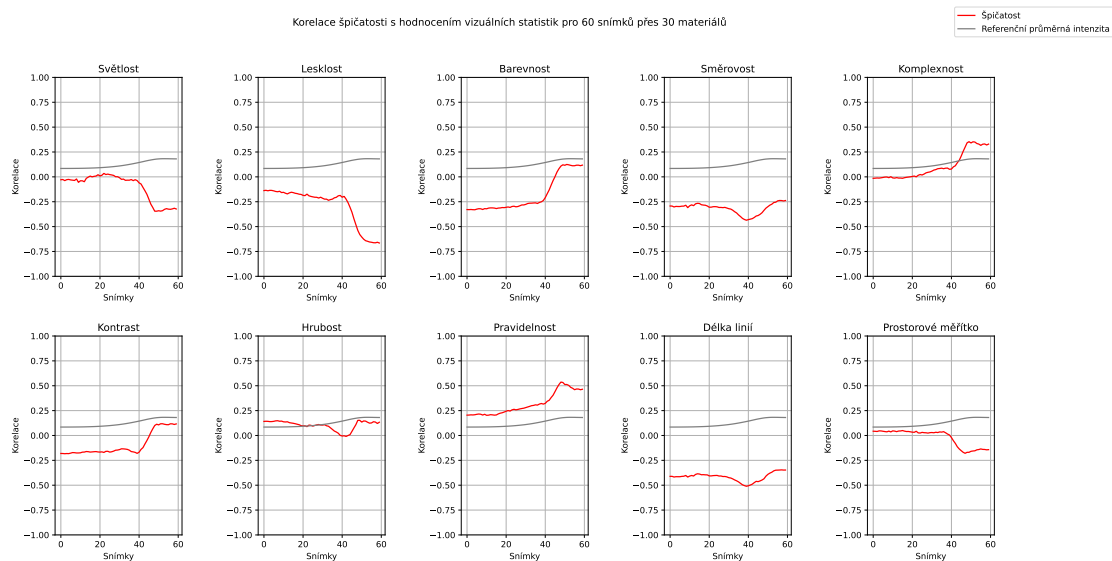





■ **Obrázek A.4** Korelace rozptylu s hodnocením vizuálních statistik pro 60 snímků přes všechny materiály.




■ **Obrázek A.5** Korelace šikmosti s hodnocením všech vizuálních statistik pro 60 snímků přes všechny materiály.




■ **Obrázek A.6** Korelace špičatosti s hodnocením vizuálních statistik pro 60 snímků přes všechny materiály.



Práh 3,00 - 2074 snímků




Práh 7,00 - 101 snímků




Práh 11,00 - 11 snímků


■ **Obrázek A.7** Mapa ponechaných snímků pro různé prahy vzdálenosti  $\Delta E$  materiálu 2. Obrázek poskytl vedoucí práce.



Práh 0,76 - 2034 snímků




Práh 2,24 - 100 snímků




Práh 5,20 - 11 snímků

■ **Obrázek A.8** Mapa ponechaných snímků pro různé prahy Euklidovské vzdálenosti výpočetních statistik materiálu 2. Obrázek poskytl vedoucí práce.



■ **Obrázek A.9** Mapa ponechaných snímků pro různé prahy vzdálenosti  $\Delta E$  materiálu 3. Obrázek poskytl vedoucí práce.

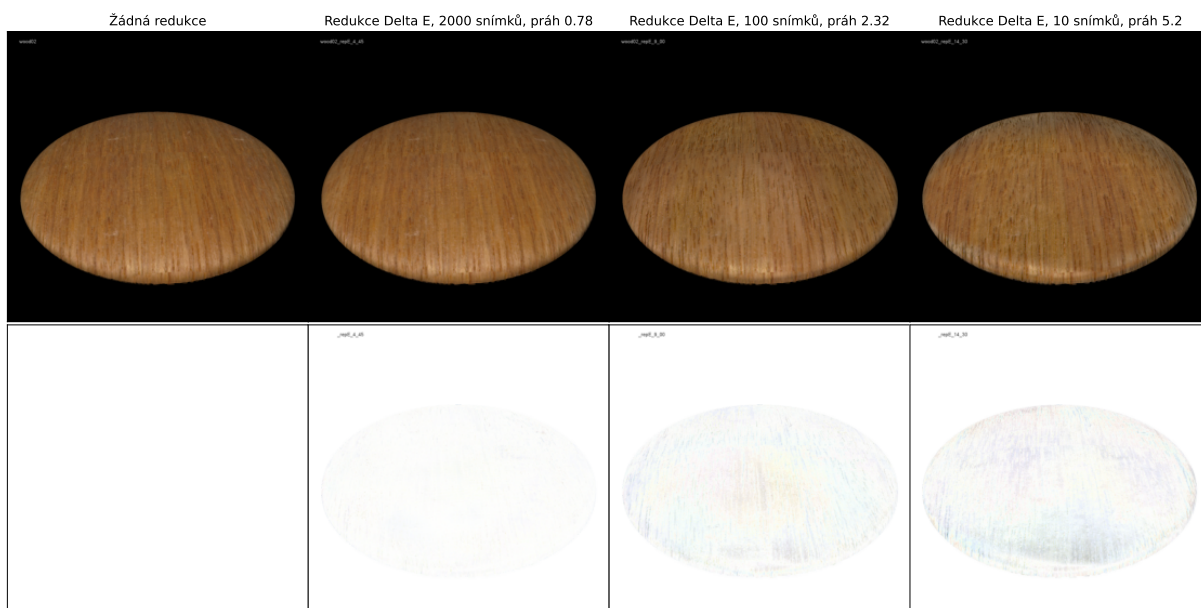


■ **Obrázek A.10** Mapa ponechaných snímků pro různé prahy Euklidovské vzdálenosti výpočetních statistik materiálu 3. Obrázek poskytl vedoucí práce.

■ **Tabulka A.1** Kolmogorova-Smirnovova odchylka histogramů luminance snímků materiálu s plnou a s omezenou množinou dat


Kolmogorov-Smirnov	2000 $\Delta E$	2000 Euklid Stat.	100 $\Delta E$	100 Euklid Stat.	10 $\Delta E$	10 Euklid Stat.
Pozice 1 Materiál 1	0,013	0,014	0,022	0,021	0,036	0,314
Pozice 1 Materiál 2	0,014	0,034	0,047	0,044	0,116	0,287
Pozice 1 Materiál 3	0,012	0,009	0,022	0,081	0,111	0,361
Pozice 2 Materiál 1	0,021	0,057	0,028	0,058	0,091	0,495
Pozice 2 Materiál 2	0,024	0,036	0,098	0,110	0,215	0,539
Pozice 2 Materiál 3	0,011	0,015	0,165	0,104	0,231	0,561

Materiál 1, pozice 2




■ **Obrázek A.11** Vizualizace materiálu 1 z pozice 2 pro plná data a poté pro různé hodnoty ponechaných snímků (práhů) společně s rozdílovými snímky oproti plným datům, redukce dat pomocí  $\Delta E$  metriky. Obrázek poskytl vedoucí práce.

Materiál 1, pozice 2




■ **Obrázek A.12** Vizualizace materiálu 1 z pozice 2 pro plná data a poté pro různé hodnoty ponechaných snímků (práhů) společně s rozdílovými snímky oproti plným datům, redukce dat pomocí Euklidovské vzdálenosti statistik. Obrázek poskytl vedoucí práce.

Materiál 2, pozice 1



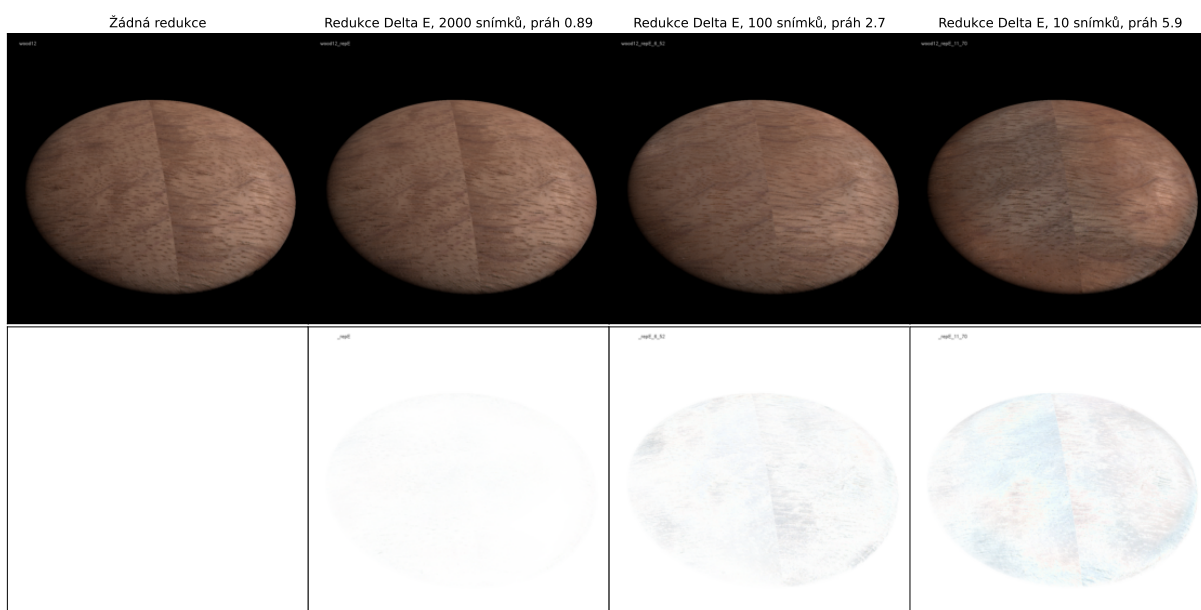
■ **Obrázek A.13** Vizualizace materiálu 2 z pozice 1 pro plná data a poté pro různé hodnoty ponechaných snímků (práhů) společně s rozdílovými snímky oproti plným datům, redukce dat pomocí  $\Delta E$  metriky. Obrázek poskytl vedoucí práce.

Materiál 2, pozice 1



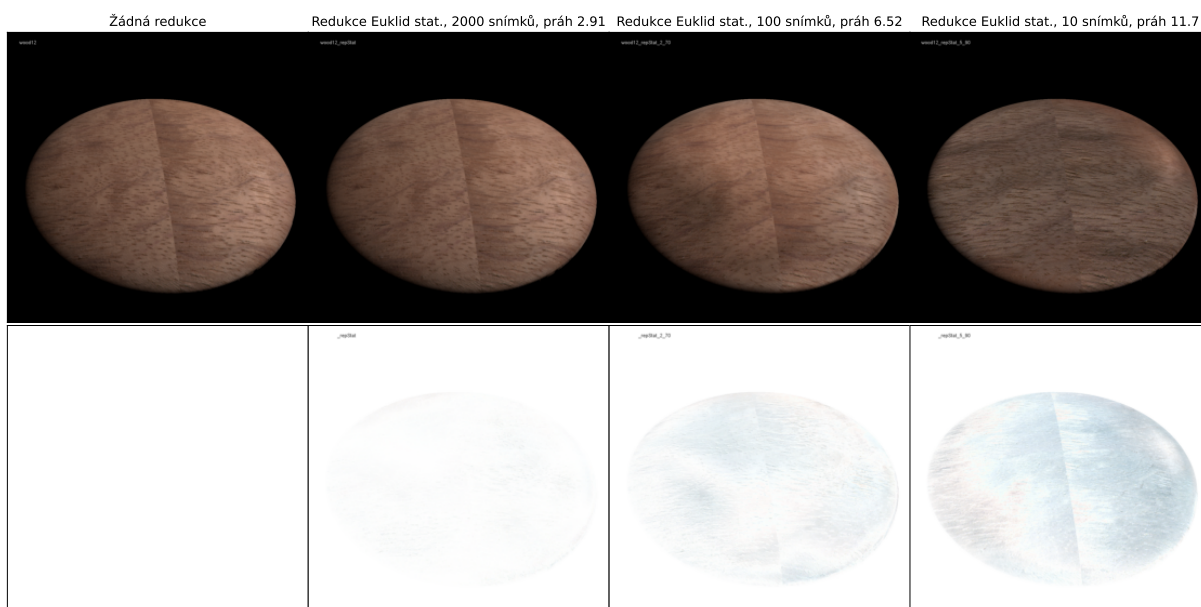
■ **Obrázek A.14** Vizualizace materiálu 2 z pozice 1 pro plná data a poté pro různé hodnoty ponechaných snímků (práhů) společně s rozdílovými snímky oproti plným datům, redukce dat pomocí Euklidovské vzdálenosti statistik. Obrázek poskytl vedoucí práce.

Materiál 3, pozice 1



■ **Obrázek A.15** Vizualizace materiálu 3 z pozice 1 pro plná data a poté pro různé hodnoty ponechaných snímků (práhů) společně s rozdílovými snímky oproti plným datům, redukce dat pomocí  $\Delta E$  metriky. Obrázek poskytl vedoucí práce.

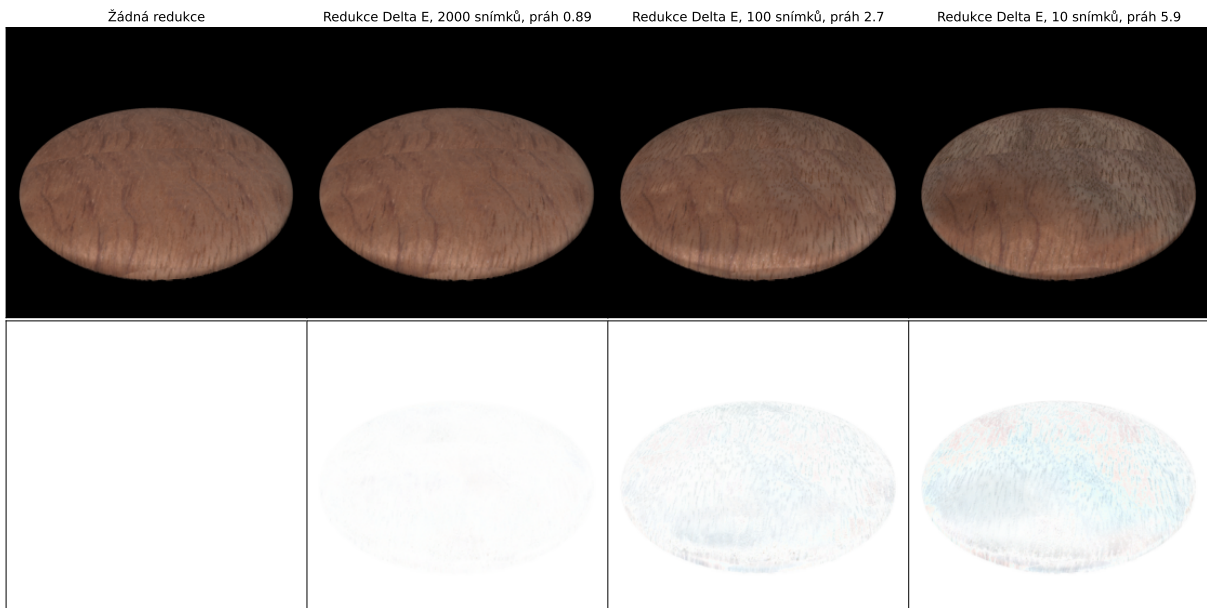
Materiál 3, pozice 1



■ **Obrázek A.16** Vizualizace materiálu 3 z pozice 1 pro plná data a poté pro různé hodnoty ponechaných snímků (práhů) společně s rozdílovými snímky oproti plným datům, redukce dat pomocí Euklidovské vzdálenosti statistik. Obrázek poskytl vedoucí práce.

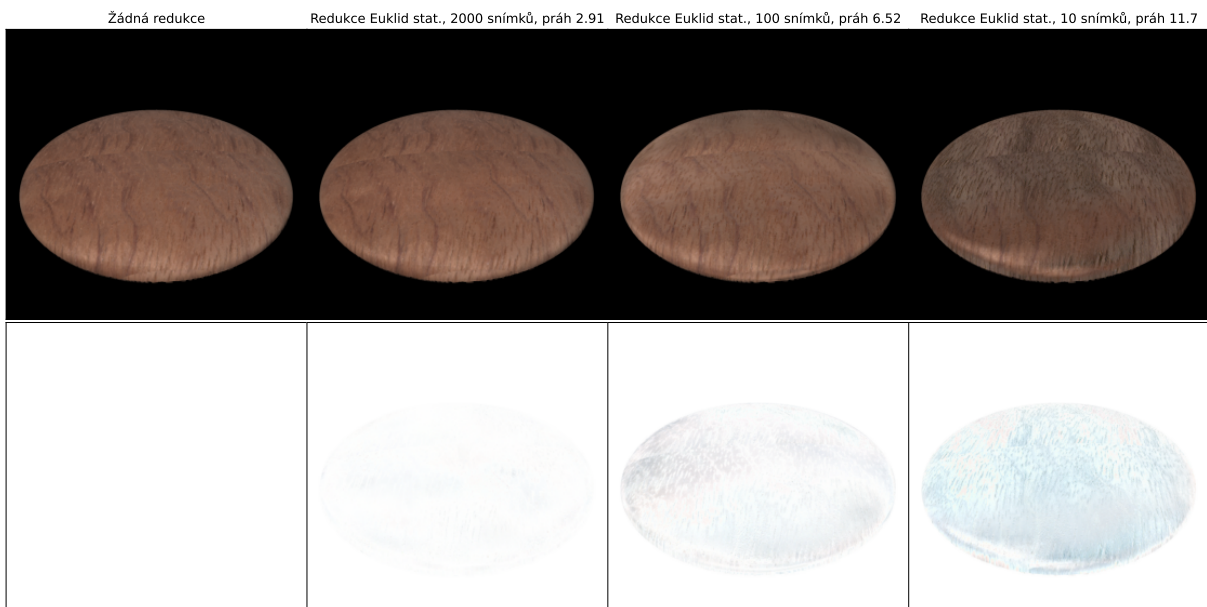


Materiál 3, pozice 2



■ **Obrázek A.17** Vizualizace materiálu 3 z pozice 2 pro plná data a poté pro různé hodnoty ponechaných snímků (práhů) společně s rozdílovými snímky oproti plným datům, redukce dat pomocí  $\Delta E$  metriky. Obrázek poskytl vedoucí práce.

Materiál 3, pozice 2



■ **Obrázek A.18** Vizualizace materiálu 3 z pozice 2 pro plná data a poté pro různé hodnoty ponechaných snímků (práhů) společně s rozdílovými snímky oproti plným datům, redukce dat pomocí Euklidovské vzdálenosti statistik. Obrázek poskytl vedoucí práce.





# Bibliografie

1. AUTODESK. *Visualization in automotive product development workflow* [online]. 2013. [cit. 2023-03-30]. Dostupné z: [https://damassets.autodesk.net/content/dam/autodesk/www/solutions/digital-prototyping/automotive/docs/pdfs/autodesk\\_automotive\\_white\\_paper\\_en\\_us\\_v2.pdf](https://damassets.autodesk.net/content/dam/autodesk/www/solutions/digital-prototyping/automotive/docs/pdfs/autodesk_automotive_white_paper_en_us_v2.pdf).
2. HAINDL, Michal; FILIP, Jiri. *Visual Texture: Accurate Material Appearance Measurement, Representation and Modeling*. 2013. vyd. London, England: Springer, 2013. Advances in Computer Vision and Pattern Recognition. ISBN 978-1-4471-4901-9.
3. RICHTER, Radek. *Realistické metody texturování* [online]. Praha: FIT ČVUT, 2017 [cit. 2023-04-25]. Dostupné z: <https://courses.fit.cvut.cz/BI-MGA/media/teacher/richttrad/mga-p12.pdf>.
4. ANDREWS, Rob W.; POLLARD, Andrew; PEARCE, Joshua M. Photovoltaic system performance enhancement with non-tracking planar concentrators: Experimental results and BDRF based modelling. In: *2013 IEEE 39th Photovoltaic Specialists Conference (PVSC)*. 2013, s. 0229–0234. Dostupné z DOI: 10.1109/PVSC.2013.6744136.
5. *Modis Land Team Home Page - BRDF/Albedo*. National Aeronautics and Space Administration, 2021. Dostupné také z: <https://modis-land.gsfc.nasa.gov/brdf.html>.
6. DERENIAK, E L; BROD, L G; HUBBS, J E. Bidirectional transmittance distribution function measurements on ZnSe. *Appl Opt.* 1982, roč. 21, č. 24, s. 4421–4425.
7. BUTLER, James J; GEORGIEV, Georgi T; COOKSEY, Catherine C. Comparison of Bidirectional Transmittance Distribution Function (BTDF) Measurements on Fused Silica and Sintered Polytetrafluoroethylene Diffusers. *Metrologia*. 2019, roč. 56, č. 6.
8. DEBEVEC, Paul; ET. AL. Acquiring the Reflectance Field of a Human Face. In: *SIGGRAPH 2000: 27th Annual Conference on Computer Graphics and Interactive Techniques*. 2000.
9. BITTERLI, Benedikt. *BSSRDF Explorer: A rendering framework for the BSSRDF*. Swiss Federal Institute of Technology Zurich, 2013.
10. YAN, Ling-Qi; ET. AL. A BSSRDF Model for Efficient Rendering of Fur with Global Illumination. *ACM Trans. Graph.* 2017, roč. 36, č. 6. ISSN 0730-0301. Dostupné z DOI: 10.1145/3130800.3130802.
11. CULA, Oana G.; ET. AL. Skin Texture Modeling. *International Journal of Computer Vision*. 2005, roč. 62, č. 1, s. 97–119. ISSN 1573-1405. Dostupné z DOI: 10.1023/B:VISI.0000046591.79973.6f.

12. AITTALA, Miika; WEYRICH, Tim; LEHTINEN, Jaakko. Two-Shot SVBRDF Capture for Stationary Materials. *ACM Trans. Graph.* 2015, roč. 34, č. 4. ISSN 0730-0301. Dostupné z DOI: 10.1145/2766967.
13. LI, Zhengqin; SUNKAVALLI, Kalyan; CHANDRAKER, Manmohan. Materials for Masses: SVBRDF Acquisition with a Single Mobile Phone Image. *CoRR*. 2018, roč. abs/1804.05790. Dostupné z arXiv: 1804.05790.
14. WOOD, Daniel N.; ET. AL. Surface light fields for 3D photography. *Proceedings of the 27th annual conference on Computer graphics and interactive techniques*. 2000.
15. PORTILLA, Javier; SIMONCELLI, Eero P. A parametric texture model based on joint statistics of complex wavelet coefficients. *International journal of computer vision*. 2000, roč. 40, s. 49–70.
16. GRIM, J; HAINDL, M. Texture modelling by discrete distribution mixtures. *Computational Statistics Data Analysis*. 2003, roč. 41, č. 3-4, s. 603–615.
17. HAINDL, M; FILIP, J. Extreme Compression and Modeling of Bidirectional Texture Function. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2007, roč. 29, č. 10, s. 1859–1865.
18. VACHER, Jonathan; BRIAND, Thibaud. The Portilla-Simoncelli Texture Model: towards Understanding the Early Visual Cortex. *Image Processing On Line*. 2021, roč. 11, s. 170–211.
19. KOUDELKA, M.L.; MAGDA, S.; BELHUMEUR, P.N.; KRIEGMAN, D.J. Acquisition, Compression, and Synthesis of Bidirectional Texture Functions. In: *Texture 2003: Proceedings of 3th International Workshop on Texture Analysis and Synthesis*. Edinburgh, UK: Heriot-Watt University, 2003, s. 47–52.
20. VASILESCU, M.A.O.; TERZOPOULOS, D. TensorTextures: Multilinear Image-Based Rendering. *ACM SIGGRAPH 2004*. 2004, roč. 23, č. 3, s. 336–342. ISSN 0730-0301.
21. WANG, H.; WU, G.; SHI, L.; YU, Y.; AHUJA, N. Out-of-core tensor approximation of multi-dimensional matrices of visual data. *ACM Transactions on Graphics*. 2005, roč. 24, č. 3, s. 527–535. ISSN 0730-0301.
22. SATTLER, M.; SARLETTE, R.; KLEIN, R. Efficient and Realistic Visualization of Cloth. In: *Eurographics Symposium on Rendering 2003*. 2003, s. 167–178.
23. MÜLLER, G.; MESETH, J.; KLEIN, R. Compression and Real-Time Rendering of Measured BTFs Using Local PCA. In: *Vision, Modeling and Visualisation 2003*. 2003, s. 271–280.
24. MALZBENDER, T.; GELB, D.; WOLTERS, H. Polynomial Texture Maps. In: *ACM SIGGRAPH 2001*. ACM Press, 2001, s. 519–528.
25. MA, Wan-Chun; CHAO, Sung-Hsiang; TSENG, Yu-Ting; CHUANG, Yung-Yu; CHANG, Chun-Fa; CHEN, Bing-Yu; OUHYOUNG, Ming. Level-of-detail representation of bidirectional texture functions for real-time rendering. In: *Proceedings of the 2005 Symposium on Interactive 3D Graphics, SI3D 2005, 4 3-6, 2005*. ACM Press, 2005, s. 187–194. ISBN 1-59593-013-2.
26. MESETH, J.; MÜLLER, G.; KLEIN, R. Preserving Realism in real-time Rendering of Bidirectional Texture Functions. In: *OpenSG Symposium*. Eurographics Association, Switzerland, 2003, s. 89–96.
27. FILIP, J.; Non-linear Reflectance Model for Bidirectional Texture Function Synthesis. In: *Proceedings of the 17th IAPR Int. Conf. on Pattern Recognition*. IEEE Press, 2004, sv. 1, s. 80–83. ISBN 0-7695-2128-2. ISSN 1051-4651.

28. MARSCHNER, S.R.; WESTIN, S.H.; ARBREE, A.; MOON, J.T. Measuring and modeling the appearance of finished wood. *ACM Transactions on Graphics*. 2005, roč. 24, č. 3, s. 727–734.
29. LAWRENCE, J.; BEN-ARTZI, A.; DECORO, C.; MATUSIK, W.; PFISTER, H.; RAMAMOORTHI, R.; RUSINKIEWICZ, S. Inverse shade trees for non-parametric material representation and editing. *ACM Transactions on Graphics*. 2006, roč. 25, č. 3, s. 735–745.
30. LEUNG, Thomas; MALIK, Jitendra. Representing and recognizing the visual appearance of materials using three-dimensional textons. *International journal of computer vision*. 2001, roč. 43, s. 29–44.
31. TONG, X.; ZHANG, J.; LIU, L.; WANG X. Guo, B.; SHUM, H.-Y. Synthesis of bidirectional texture functions on arbitrary surfaces. In: *ACM SIGGRAPH 2002*. ACM Press, 2002, s. 665–672.
32. EFROS, A. A.; FREEMAN, W. T. Image Quilting for Texture Synthesis and Transfer. In: *ACM SIGGRAPH 2001*, ACM Press. 2001, s. 341–346.
33. KAWASAKI, H.; SEO, Kyoung-Dae; OHSAWA, Y.; FURUKAWA, R. Patch-Based BTF Synthesis for Real-Time Rendering. In: *IEEE International Conference on Image Processing, ICIP*. IEEE, 2005, sv. 1, s. 393–396.
34. HAINDL, M.; HATKA, M. BTF Roller. In: *Texture 2005: Proceedings of 4th International Workshop on Texture Analysis and Synthesis*. Heriot-Watt University, 2005, s. 89–94.
35. SOMOL, P.; HAINDL, M. Novel Path Search Algorithm for Image Stitching and Advanced Texture Tiling. In: *Proceedings of 13-th Inter. Conf. in Central Europe on Computer Graph., Visual. and Comp. Vis., WSCG*. 2005, s. 155–162. ISBN 80-903100-7-9.
36. COHEN, M.F.; SHADE, J.; HILLER, S. et al. Wang Tiles for image and texture generation. *ACM Transactions on Graphic*. 2003, roč. 22, č. 3, s. 287–294.
37. LEUNG, Chi-Sing; PANG, Wai-Man; FU, Chi-Wing; WONG, Tien-Tsin; HENG, Pheng-Ann. Tileable BTF. *IEEE Transactions on Visualization and Computer Graphics*. 2007, roč. 13, č. 5, s. 935–955.
38. LIU, Li; CHEN, Jie; FIEGUTH, Paul; ZHAO, Guoying; CHELLAPPA, Rama; PIETIKÄINEN, Matti. From BoW to CNN: Two decades of texture representation for texture classification. *International Journal of Computer Vision*. 2019, roč. 127, č. 1, s. 74–109.
39. DONG, Yue. Deep appearance modeling: A survey. *Visual Informatics*. 2019, roč. 3, č. 2, s. 59–68.
40. MAXIMOV, Maxim; LEAL-TAIXÉ, Laura; FRITZ, Mario; RITSCHHEL, Tobias. Deep appearance maps. In: *Proceedings of the IEEE/CVF International Conference on Computer Vision*. 2019, s. 8729–8738.
41. DELANOY, J; LAGUNAS, M; CONDOR, J; GUTIERREZ, D; MASIA, B. A Generative Framework for Image-based Editing of Material Appearance using Perceptual Attributes. *Computer Graphics Forum*. 2022.
42. LI, Xiao; DONG, Yue; PEERS, Pieter; TONG, Xin. Modeling surface appearance from a single photograph using self-augmented convolutional neural networks. *ACM Transactions on Graphics (ToG)*. 2017, roč. 36, č. 4, s. 1–11.
43. KANG, Kaizhang; CHEN, Zimin; WANG, Jiaping; ZHOU, Kun; WU, Hongzhi. Efficient reflectance capture using an autoencoder. *ACM Trans. Graph.* 2018, roč. 37, č. 4, s. 127–1.
44. DESCHAINTE, Valentin; AITTALA, Miika; DURAND, Fredo; DRETTAKIS, George; BOUSSEAU, Adrien. Single-image svbrdf capture with a rendering-aware deep network. *ACM Transactions on Graphics (ToG)*. 2018, roč. 37, č. 4, s. 1–15.

45. GAO, Duan; LI, Xiao; DONG, Yue; PEERS, Pieter; XU, Kun; TONG, Xin. Deep inverse rendering for high-resolution SVBRDF estimation from an arbitrary number of images. *ACM Trans. Graph.* 2019, roč. 38, č. 4, s. 134–1.
46. KUZNETSOV, Alexandr; HASAN, Milos; XU, Zexiang; YAN, Ling-Qi; WALTER, Bruce; KALANTARI, Nima Khademi; MARSCHNER, Steve; RAMAMOORTHY, Ravi. Learning generative models for rendering specular microgeometry. *ACM Trans. Graph.* 2019, roč. 38, č. 6, s. 225–1.
47. ZHANG, Hang; XUE, Jia; DANA, Kristin. Deep ten: Texture encoding network. In: *Proceedings of the IEEE conference on CVPR.* 2017, s. 708–717.
48. BIAN, Peng; LI, Wanwan; JIN, Yi; ZHI, Ruicong. Ensemble feature learning for material recognition with convolutional neural networks. *EURASIP Journal on Image and Video Processing.* 2018, roč. 2018, č. 1, s. 1–11.
49. ZHANG, Xiaohua; DONG, Junyu; GAN, Yanhai; YU, Hui; QI, Lin. BTF data Generation based on Deep Learning. *Procedia computer science.* 2019, roč. 147, s. 233–239.
50. RAINER, Gilles; JAKOB, Wenzel; GHOSH, Abhijeet; WEYRICH, Tim. Neural BTF compression and interpolation. In: *Computer Graphics Forum.* Wiley Online Library, 2019, sv. 38, s. 235–244. Č. 2.
51. TADA, Naoki; HIRAI, Keita. BTF image recovery based on U-Net and texture interpolation. *Electronic Imaging.* 2020, roč. 2020, č. 5, s. 32–1.
52. RAINER, Gilles; GHOSH, Abhijeet; JAKOB, Wenzel; WEYRICH, Tim. Unified neural encoding of BTFs. In: *Computer Graphics Forum.* Wiley Online Library, 2020, sv. 39, s. 167–178. Č. 2.
53. LANDY, Michael S.; GRAHAM, Norma. Visual Perception of Texture. In: *THE VISUAL NEUROSCIENCES.* MIT Press, 2004, s. 1106–1118.
54. FLEMING, Roland W. Visual perception of materials and their properties. *Vision Research.* 2014, roč. 94, č. 0, s. 62–75.
55. TAMURA, H.; MORI, S.; YAMAWAKI, T. Textural features corresponding to visual perception. *Systems, Man and Cybernetics, IEEE Transactions on.* 1978, roč. 8, č. 6, s. 460–473.
56. BRODATZ, P. *A Photographic Album for Artists and Designers (Brodatz Texture Database).* Dover Publications, 1966.
57. RAVISHANKAR RAO, A.; LOHSE, G.L. Towards a texture naming system: Identifying relevant dimensions of texture. *Vision Research.* 1996, roč. 36, č. 11, s. 1649–1669.
58. HEAPS, C.; HANDEL, S. Similarity and features of natural textures. *Journal of Experimental Psychology: Human Perception and Performance.* 1999, roč. 25, č. 2, s. 299.
59. MOJSILOVIC, A.; KOVACEVIC, J.; KALL, D.; SAFRANEK, R.J.; KICHA GANAPATHY, S. The vocabulary and grammar of color patterns. *Image Processing, IEEE Transactions on.* 2000, roč. 9, č. 3, s. 417–431.
60. FLEMING, Roland W; WIEBEL, Christiane; GEGENFURTNER, Karl. Perceptual qualities and material classes. *Journal of vision.* 2013, roč. 13, č. 8, s. 9–9.
61. TANAKA, Midori; HORIUCHI, Takahiko. Investigating perceptual qualities of static surface appearance using real materials and displayed images. *Vision research.* 2015, roč. 115, s. 246–258.
62. VANRELL, M.; VITRIA, J.; ROCA, X. A Multidimensional Scaling approach to explore the behavior of a texture perception algorithm. *Machine Vision and Applications.* 1997, roč. 9, č. 5/6, s. 262–271.

63. SCHWARTZ, G.; NISHINO, K. Visual Material Traits: Recognizing Per-Pixel Material Context. In: *2013 IEEE International Conference on Computer Vision Workshops*. 2013, s. 883–890.
64. SCHWARTZ, G.; NISHINO, K. Automatically discovering local visual material attributes. In: *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2015, s. 3565–3573.
65. SHARAN, Lavanya; LIU, Ce; ROSENHOLTZ, Ruth; ADELSON, Edward H. Recognizing Materials Using Perceptually Inspired Features. *International Journal of Computer Vision*. 2013, roč. 103, č. 3, s. 348–371.
66. FILIP, J.; CHANTLER, M.J.; GREEN, P.R.; HAINDL, M. A Psychophysically Validated Metric for Bidirectional Texture Data Reduction. *ACM Transactions on Graphics*. 2008, roč. 27, č. 5, s. 138.
67. JARABO, A.; WU, H.; DORSEY, J.; RUSHMEIER, H.; GUTIERREZ, D. Effects of Approximate Filtering on the Appearance of Bidirectional Texture Functions. *IEEE Transactions on Visualization and Computer Graphics*. 2014, roč. 20, č. 6, s. 880–892. ISSN 1077-2626. Dostupné z DOI: 10.1109/TVCG.2014.2312016.
68. RAMANARAYANAN, G.; FERWERDA, J.; WALTER, B.; BALA, K. Visual equivalence: towards a new standard for image fidelity. *ACM Transactions on Graphics*. 2007, roč. 26, č. 3, 76:1–76:10.
69. MARTÍN, Rodrigo; ISERINGHAUSEN, Julian; WEINMANN, Michael; HULLIN, Matthias B. Multimodal Perception of Material Properties. In: *Proceedings of the ACM SIGGRAPH Symposium on Applied Perception*. Tübingen, Germany, 2015, s. 33–40. SAP '15. ISBN 978-1-4503-3812-7. Dostupné z DOI: 10.1145/2804408.2804420.
70. HAGH-SHENAS, Haleh; INTERRANTE, Victoria; HEE-PARK, Cheong. A closer look at texture metrics for visualization. In: *Human Vision and Electronic Imaging XI*. SPIE, 2006, sv. 6057, s. 321–331.
71. MASKEY, Manil; NEWMAN, Timothy S. On measuring and employing texture directionality for image classification. *Pattern Analysis and Applications*. 2021, roč. 24, č. 4, s. 1649–1665.
72. FILIP, Jiří; KOLAFOVÁ, Martina; HAVLÍČEK, Michal; VÁVRA, Radomír; HAINDL, Michal; RUSHMEIER, Holly. Evaluating physical and rendered material appearance. *The Visual Computer*. 2018, roč. 34, s. 805–816.
73. NUMPY DEVELOPERS. *API Reference - Routines - Mathematical functions* [online]. 2023. [cit. 2023-05-10]. Dostupné z: <https://numpy.org/doc/stable/reference/routines.math.html>.
74. THE SCIPY COMMUNITY. *Statistical functions (scipy.stats) - SciPy v1.10.1 Manual* [online]. 2023. [cit. 2023-05-10]. Dostupné z: <https://docs.scipy.org/doc/scipy/reference/stats.html>.
75. VANDENBROUCKE, Bert. *Computing a power spectrum in Python | Bert's blog — bertvandenbroucke.netlify.app* [online]. 2019. [cit. 2023-04-17]. Dostupné z: <https://bertvandenbroucke.netlify.app/2019/05/24/computing-a-power-spectrum-in-python/>.
76. NOVÁK, Petr; ET. AL. *Náhodné vektory II. (konvoluce, kovariance, korelace)* [online]. Praha: FIT ČVUT, 2022 [cit. 2022-11-09]. Dostupné z: <https://courses.fit.cvut.cz/BI-PST/media/lectures/BI-PST-Lec07-Slides.pdf>.
77. NUMPY DEVELOPERS. *API Reference - Routines - Statistics* [online]. 2023. [cit. 2023-05-10]. Dostupné z: <https://numpy.org/doc/stable/reference/routines.statistics.html>.



78. VAŠATA, Daniel. *Redukce dimenzionality - analýza hlavních komponent, lokálně lineární vnoření* [online]. Praha: FIT ČVUT, 2023 [cit. 2023-03-15]. Dostupné z: <https://courses.fit.cvut.cz/BI-ML2/lectures/files/BI-ML2-04-cs-slides.pdf>.
79. SCIKIT-LEARN DEVELOPERS. *API Reference - scikit-learn 1.2.2* [online]. 2023. [cit. 2023-05-10]. Dostupné z: <https://scikit-learn.org/stable/modules/classes.html>.
80. VAŠATA, Daniel; KLOUDA, Karel. *Lineární regrese - metoda nejmenších čtverců* [online]. Praha: FIT ČVUT, 2022 [cit. 2022-10-13]. Dostupné z: <https://courses.fit.cvut.cz/BI-ML1/lectures/files/BI-ML1-04-cs-slides.pdf>.
81. VAŠATA, Daniel; KLOUDA, Karel. *Hřebenová regrese, vztah vychýlení a rozptylu (bias-variance trade-off), statistické vlastnosti lineární regrese* [online]. Praha: FIT ČVUT, 2022 [cit. 2022-10-27]. Dostupné z: <https://courses.fit.cvut.cz/BI-ML1/lectures/files/BI-ML1-06-cs-slides.pdf>.
82. VAŠATA, Daniel; KLOUDA, Karel. *Evaluace modelů, křížová validace* [online]. Praha: FIT ČVUT, 2022 [cit. 2022-11-24]. Dostupné z: <https://courses.fit.cvut.cz/BI-ML1/lectures/files/BI-ML1-09-cs-slides.pdf>.
83. ZEILEIS, Achim; HORNIK, Kurt; MURRELL, Paul. Escaping RGBland: Selecting colors for statistical graphics. *Computational Statistics & Data Analysis*. 2009, roč. 53, č. 9, s. 3259–3270. ISSN 0167-9473. Dostupné z DOI: <https://doi.org/10.1016/j.csda.2008.11.033>.
84. AG, Basler; KARSTENS, Frank. *What is the RGB color space? — baslerweb.com* [online]. 2023. [cit. 2023-04-23]. Dostupné z: <https://www.baslerweb.com/en/sales-support/knowledge-base/frequently-asked-questions/what-is-the-rgb-color-space/15179/>.
85. STONE, Elle. *Programmers Guide to XYZ, RGB* [online]. 2015. [cit. 2023-04-23]. Dostupné z: <https://ninedegreesbelow.com/photography/xyz-rgb.html#xyY>.
86. MOUW, Tim. *LAB Color Space and Values* [online]. 2018. [cit. 2023-04-23]. Dostupné z: <https://www.xrite.com/blog/lab-color-space>.
87. KONICA MINOLTA SENSING. *Understanding the CIE L\*a\*b\* Color Space — sensing.konicaminolta.us* [online]. 2022. [cit. 2023-04-23]. Dostupné z: <https://sensing.konicaminolta.us/us/blog/understanding-the-cie-lch-color-space/>.
88. VAŠATA, Daniel; KLOUDA, Karel. *Nesupervizované učení, Hierarchická shlukování, algoritmus k-means* [online]. Praha: FIT ČVUT, 2022 [cit. 2022-12-08]. Dostupné z: <https://courses.fit.cvut.cz/BI-ML1/lectures/files/BI-ML1-11-cs-slides.pdf>.
89. SCHUESSLER, Zachary. *Delta E 101* [online]. 2019. [cit. 2023-04-23]. Dostupné z: <http://zschuessler.github.io/DeltaE/learn/>.
90. MESHGI, Kourosh. *Histogram\_of\_Color\_Advancements - dist\_chisquare* [online]. 2014. [cit. 2023-04-24]. Dostupné z: [https://github.com/meshgi/Histogram\\_of\\_Color\\_Advancements/blob/master/distance/dist\\_chisquare.m](https://github.com/meshgi/Histogram_of_Color_Advancements/blob/master/distance/dist_chisquare.m).
91. MESHGI, Kourosh. *Histogram\_Color\_Advancements - dist\_ks* [online]. 2014. [cit. 2023-04-24]. Dostupné z: [https://github.com/meshgi/Histogram\\_of\\_Color\\_Advancements/blob/master/distance/dist\\_ks.m](https://github.com/meshgi/Histogram_of_Color_Advancements/blob/master/distance/dist_ks.m).
92. ZWENG, Andreas; RITTLER, Thomas; KAMPEL, Martin. Evaluation of Histogram-Based Similarity Functions for Different Color Spaces. In: *Computer Analysis of Images and Patterns*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011, s. 455–462. ISBN 978-3-642-23678-5.
93. NUMPY DEVELOPERS. *API Reference - Array objects - The N-dimensional array (ndarray)* [online]. 2023. [cit. 2023-05-10]. Dostupné z: <https://numpy.org/doc/stable/reference/arrays.ndarray.html>.

94. SCHWARTZ, Christopher; SARLETTE, Ralf; WEINMANN, Michael; RUMP, Martin; KLEIN, Reinhard. Design and Implementation of Practical Bidirectional Texture Function Measurement Devices Focusing on the Developments at the University of Bonn. *Sensors*. 2014, roč. 14, č. 5, s. 7753–7819. ISSN 1424-8220. Dostupné z DOI: 10.3390/s140507753.
95. CONTRIBUTORS TO THE OPENEXR PROJECT. *Technical Introduction to OpenEXR* — *openexr.com* [online]. 2021. [cit. 2023-04-20]. Dostupné z: <https://openexr.com/en/latest/TechnicalIntroduction.html#overview-of-the-openexr-file-format>.
96. FILIP, J.; LUKAVSKY, J.; DECHTERENKO, F.; FLEMING, R.; SCHMIDT, F. Perceptual Dimensions of Wood Materials. *PsyArXiv*. 2023. Dostupné z DOI: doi:10.31234/osf.io/3qkz9.
97. TURNER, M. R. Texture discrimination by Gabor functions. *Biological Cybernetics*. 1986, roč. 55, č. 2, s. 71–82. ISSN 1432-0770. Dostupné z DOI: 10.1007/BF00341922.
98. MESHGI, Kouros; ISHII, Shin. Expanding Histogram of Colors with Gridding to Improve Tracking Accuracy. In: *MVA2015 IAPR International Conference on Machine Vision Applications*. Tokyo, Japan, 2015, s. 475–479.
99. MOTOYOSHI, Isamu; NISHIDA, Shin'ya; SHARAN, Lavanya; ADELSON, Edward. Image statistics and the perception of surface qualities. *Nature*. 2007, roč. 447, s. 206–9. Dostupné z DOI: 10.1038/nature05724.





# Obsah přiloženého archivu

readme.txt	.....	stručný popis obsahu archivu a další informace
code_jupyter	.....	Jupyter notebooky se zdrojovým kódem
code_html	.....	Jupyter notebooky ve formě HTML stránek
data		
material_set_1		
1-30		
compress_index_matrix	.....	matice nahrazených indexů
distance_matrix	.....	vzdálenostní matice
stats_btf	.....	statistiky spočítané na BTF datech
stats_video	.....	statistiky spočítané na video datech
material_set_2		
1-30		
stats_video	.....	statistiky spočítané na video datech
visual_rating	.....	hodnocení vizuálních statistik z psychovizuálních experimentů
thesis		
latex_source	.....	zdrojová forma práce ve formátu L <sup>A</sup> T <sub>E</sub> X
thesis.pdf	.....	text práce ve formátu PDF