

Uniwersytet Wrocławski

Wydział Matematyki i Informatyki
Instytut Informatyki

Piotr Didyk

Zwiększanie kontrastu jasnych obiektów w nagraniach video dla wyświetlaczy HDR.

Praca magisterska napisana pod kierunkiem:
dr Andrzeja Łukaszewskiego

we współpracy z MPI Informatik, Niemcy:
dr Rafał Mantiuk
dr hab. Karol Myszkowski

Wrocław 2008

Miniejsza praca podzielona jest na dwie części.

Pierwsza to opis przebiegu prac nad projektem „Enhancement of Bright Video Features for High Dynamic Range Display” zrealizowanym w Instytucie Maxa Plancka w Niemczech.

Druga część to artykuł dotyczący zrealizowanego projektu, który zostanie zaprezentowany na Eurographics Symposium on Rendering w czerwcu 2008 roku.

Artykuł zostanie także opublikowany w czasopiśmie: „Computer Graphics Forum The International Journal of the Eurographics Association”.

Przebieg prac nad projektem „Enhancement of bright video features for high dynamic range display” zrealizowanym w Instytucie Maxa Plancka w Saarbrücken

1 Wstęp

Pracę nad projektem zacząłem podczas letniego semestru na 4. roku moich studiów, kiedy wyjechałem na stypendium naukowe z programu Socrates-Erasmus do Saarbrücken. Po przyjeździe skontaktowałem się z Karolem Myszkowskim, pracownikiem naukowym Instytutu Maxa Plancka, który zaproponował mi współpracę z Rafałem Mantiukiem. Początkowo pracowałem nad projektem, który nie był związany z moją pracą magisterską, a dotyczył zautomatyzowanego odtwarzania obrazów o podwyższonym zakresie dynamicznym (ang. high dynamic range - HDR) z dużego zbioru zdjęć o niskim zakresie dynamicznym (ang. low dynamic range - LDR). Prace nad nim trwały dwa miesiące, po których otrzymałem od Rafała propozycję realizacji projektu, dotyczącego zagadnienia *LDR to HDR*, czyli odtwarzania obrazów HDR, mając do dyspozycji jedno zdjęcie LDR. Po konsultacji z Karolem oraz Andrzejem Łukaszewskim, podjąłem się realizacji tego projektu oraz postanowiłem, że będzie on jednocześnie moją pracą magisterską. W poniższym raporcie pragnę przedstawić przebieg prac nad tym projektem jak również mój wkład w niego.

2 Założenia projektu

Problem *LDR to HDR* jest w ostatnim czasie modnym zagadnieniem. Wynika to przede wszystkim z rozwoju technologii produkcji nowoczesnych wyświetlaczy, które oferują coraz lepszy zakres dynamiczny. Żeby czerpać korzyści wynikające z nowych możliwości wyświetlaczy, potrzebna jest metoda wyświetlania na nich materiałów LDR. Naszym celem było stworzenie metody, która przystosowuje materiał LDR do wyświetlania na nowoczesnych wyświetlaczach. W szczególności skupiliśmy się nad problemem regionów obciętych, regionów, których jasność przekracza zakres dynamiczny sprzętu rejestrującego.

Nasza metoda miała składać się z trzech kroków:

- wykrywanie obciętych regionów, które wymagają edycji
- klasyfikacja obiektów na trzy grupy: tekstury, odbicia, źródła światła
- rekonstrukcja obiektów w zależności jak zostały sklasyfikowane

Założenie początkowe było takie, że nasza metoda będzie w pełni automatyczna. Najlepszy scenariusz zakładał, że naszą metodę będzie można zaimplementować na GPU, a wszelka edycja będzie wykonywana w czasie rzeczywistym podczas wyświetlania filmu. Jak się potem okazało, nie jest to takie proste. W następnych częściach chciałbym przedstawić jak nasz projekt ewoluował

do ostatecznej wersji. Moje sprawozdanie będzie oparte o plan prac, w którym z inicjatywy Rafała były spisywane plany na kolejne tygodnie prac, a także odnotowywane rzeczy, które były zrealizowane.

3 Przebieg prac

3.1 Początek prac

Prace nad projektem zaczęły się jeszcze w lipcu 2007 roku. Wiedzieliśmy wtedy, że chcemy w jakiś sposób klasyfikować obiekty, które wymagają rekonstrukcji, na podstawie wyliczonych statystyk dla poszczególnych obiektów, biorąc po uwagę także rejony je otaczające. Okres do wakacji został poświęcony przeze mnie na czytanie wcześniejszych artykułów dotyczących tego tematu jak również na sprawdzenie statystyk zaproponowanych przez Rafała. Stan prac na dzień mojego wyjazdu z Saarbrücken po semestralnym pobycie wyglądał następująco:

- Po przeanalizowaniu literatury z lat poprzednich okazało się, że poza paroma metodami, które dotyczyły problemu *LDR to HDR* dla obrazów i nie mogły być zastosowane dla filmów z powodu braku spójności czasowej, jedyną pracą w której upatrywaliśmy potencjalnego konkurenta, to praca z roku poprzedniego z konferencji SIGGRAPH. Zdawaliśmy sobie jednak sprawę z jej problemów, które zamierzaliśmy rozwiązać.
- Proste i intuicyjne statystyki wykorzystujące znane zjawiska, takie jak np. efekt glare, nie dawały takich efektów jakich byśmy oczekiwali.

Efekt glare jest jednym z efektów związanych ze źródłami światła. Polega on na rozpraszaniu się światła w powietrzu, co powoduje powstawanie wokół źródeł światła jasnych obwóddek.

Na miesięczne wakacje, które postanowiłem sobie zrobić, zostałem z problemem nowych statystyk, które mogłyby dać lepsze rezultaty, a także z zapoznaniem się z metodami klasyfikacji, o których nie miałem wystarczającej wiedzy. Z pomocą przyszła książka - „Pattern classification” - Duda, Hart, Stork.

3.2 Prace nad klasyfikatorem cz. 1

We wrześniu nowego roku akademickiego 2007/2008 wróciłem do Saarbrücken w celu wznowienia prac na projektem. Nie uczęszczałem w tym czasie na żadne zajęcia, więc cały swój czas mogłem poświęcić na realizację projektu. Ponieważ przygotowywaną pracę chcieliśmy wysłać na konferencję Computer Vision and Pattern Recognition (CVPR) mieliśmy 3 miesiące na ukończenie prac.

Prace ruszyły od pierwszego dnia mojego pobytu. Mimo, że Rafał przez cały wrzesień był pochłonięty innymi obowiązkami, raz na tydzień organizowaliśmy godzinne spotkania, które miały ukierunkować moje prace.

Cały wrzesień poświęciłem pracom nad klasyfikatorem oraz zbieraniu do niego danych testowych. Na początku stanowiły one zdjęcia z serwisu Flickr. W zgromadzonych przeze mnie zdjęciach znajdowało się ok. 1000 obiektów, które został przeze mnie sklasyfikowane ręcznie za pomocą stworzonego do tego celu narzędzia.

Wspomagając się literaturą dotyczącą klasyfikacji oraz problemów z wykrywaniem w obrazach rozświetleń (ang. highlights), stworzyłem ok. 30 różnych statystyk, za którymi stały intuicje dotyczące zjawisk fizycznych zachodzących w obiektach, efektów powodowanych przy rejestracji i przetwarzaniu filmów oraz kształtów obiektów. Przy takich zagadnieniach często pojawia się problem, jak oceniać statystyki. Wizualnie można to stwierdzić dla dwóch statystyk rysując

wykresy zależności jednej od drugiej jako chmurę punktów. Jednak problem pojawia się zawsze, gdy dochodzą kolejne wymiary, dlatego wykorzystałem także wykresy obrazujące *bayes decision rule* dla każdej ze statystyk.

Bayes decision rule jest to zasada klasyfikacji, minimalizująca prawdopodobieństwo błędu. W prostym przypadku, mając policzoną pewną statystkę x obiektu α , który musi być przyporządkowany do jednej z dwóch klas ω_1 lub ω_2 , oraz prawdopodobieństwo $p(\omega_1|x)$ oraz $p(\omega_2|x)$, *bayes decision rule* to:

$$\alpha \in \omega_1 \text{ jeżeli } p(\omega_1|x) \geq p(\omega_2|x) \text{ wpp. } \alpha \in \omega_2.$$

$$p(error|x) = \min[p(\omega_1|x), p(\omega_2|x)]$$

Należy pamiętać, że nigdy nie mamy do dyspozycji prawdopodobieństw $p(\omega_i|x)$. Możemy je jedynie estymować.

Szybko się jednak okazało, że znalezienie statystyk, które przy wykorzystaniu klasyfikatorów, które uczyłyby się w trybie offline i osiągałyby sensowną skuteczność jest bardzo trudne. Nasze statystyki przy użyciu różnych klasyfikatorów off-line (korzystałem z toolboxa PRTools [2], który zawierał implementacje wielu klasyfikatorów) dawały błąd ok. 40%, co dla nas było nie do przyjęcia, ponieważ chcieliśmy, aby nasza metoda była automatyczna.

Główną przyczyną tak słabych wyników było to, że dostępne filmy DVD są wbrew pozorom niskiej jakości. Szumy, obróbki w studiu, których dokonuje się po nakręceniu filmu a także dynamicznie zmieniające się sceny powodują, że efekty na których bazowały moje statystyki były za słabe, aby dawały pożądane odzwierciedlenie w wartościach statystyk. Dopóki zdjęcia wykonane były w wysokiej jakości w laboratorium, wszystkie intuicje miały pełne uzasadnienie. Jednak, gdy przyszło zastosować je w filmach, pojawiły się poważne problemy, dlatego też moje prace nad statystykami, inspirowane także przez Rafała i Matthiasa (trzeciego autora artykułu) trwały praktycznie do końca.

Ponieważ mijał już pierwszy miesiąc pracy nad projektem, postanowiliśmy nie skupiać wszystkich swoich sił na klasyfikacji, ale zacząć równolegle badać problem rekonstrukcji regionów obciętych.

3.3 Rekonstrukcja obszarów cz.1

Prace nad metodą rekonstrukcji zacząłem od zrobienia zdjęć HDR różnych źródeł światła jak również ich odbić w laboratorium fotograficznym. Zdjęcia te potwierdziły naszą wiedzę na temat wyglądu profili źródeł światła oraz odbić, a ponieważ profile te miały różny charakter, potwierdziło to także zasadność naszej klasyfikacji.

Zanim zacząłem próby z bardziej skomplikowanymi metodami wypróbowałem te najprostsze, po części wykorzystywane wcześniej. Próby te ujawniły problemy, z którymi musieliśmy się zmierzyć.

Pierwsza najprostsza metoda wykorzystywała rozmytą maskę regionów obciętych jako funkcję rozciągającą kontrast. Metoda dawała wyobrażenie jak może wyglądać efekt takiej edycji, jednak rozmywała ona krawędzie oraz nie sprawdzała się na obiektach o skomplikowanych kształtach.

Wypróbowałem także metody zachowujące pochodne na krawędziach regionów, jak również ekstrapolacje (były to metody których implementacja została mi dostarczona przez Rafała).

Żadna z tych metod nie dała satysfakcjonujących rezultatów. Wszystkie były bardzo wrażliwe na dystorsje w filmach wideo jak również na skomplikowane kształty. Najbardziej zaawansowaną metodą jaką sprawdziliśmy była metoda naszego autorstwa. Polegała ona na tym, że na podstawie profili uzyskanych ze zdjęć w studio stworzyliśmy model takich profili dla źródła światła oraz odbicia oparty o funkcje sigmoidalne. Następnie opracowaliśmy metodę do wpasowywania profili,

biorąc pod uwagę sąsiedztwo krawędzi regionów obciętych. Metoda ta mimo, że zawarliśmy w niej w pełni idee rekonstrukcji, także się nie sprawdziła. Miała problemy ze skomplikowanymi kształtami, oraz okazało się, podobnie jak w przypadku statystyk do klasyfikatora, że nie można polegać na otoczeniach regionów obciętych. Wszystkie metody wykorzystujące większe niż 1-2 pikselowe otoczenie regionów dawały niespójne po czasie rekonstrukcje obszarów.

Funkcje sigmoidalne są to funkcje o kształcie zbliżonym do litery S, o podstawowej postaci $S(t) = \frac{1}{1+e^{-t}}$. Kombinacje wielu takich funkcji są wykorzystywane np. do przybliżania funkcji mapujących tony. Tutaj zostały wykorzystane do zbudowania funkcji, która przybliżała profile źródeł światła oraz odbić.

3.4 Klasifikator cz.2

Równoległe z pracami nad rekonstrukcją dalej posuwały się prace nad klasyfikacją. Ponieważ posiadany przez nas klasyfikator generował błąd dla nas niedopuszczalny, postanowiliśmy skorzystać z faktu, że zajmujemy się filmami i wykorzystać informacje z tym idące. Pierwszym krokiem było znalezienie przeze mnie algorytmu rozwiązującego problem *optical flow* i wykorzystanie go do kojarzenia obiektów z sąsiednich klatek.

Optical flow jest jednym z podstawowych problemów z zakresu *computer vision*. Najczęściej definiuje się go dla dwóch obrazów, dla których należy znaleźć wektory przesunięcia (ang. *moution vectors*). Wektory te wyznaczają dla każdego miejsca w pierwszym obrazie jego przesunięcie w stosunku do drugiego obrazu. Powszechnie znanymi rozwiązaniami tego problemu są metody optymalizacyjne, które z jednej strony mają za zadanie zachować ciągłość wektorów przesunięcia, z drugiej zaś dbają o zachowanie wartości obrazu bądź gradientów.

Wybrałem jeden z algorytmów rozwiązujący problem *optical flow*, zaimplementowany w bibliotece OpenCV [3]. Algorytm ten zwraca motion vector dla danego piksela w klatce. Ponieważ algorytmy rozwiązujące problem *optical flow* zwykle mają problemy z obiektami bardzo dynamicznymi, moimi danymi dla problemu *optical flow* nie były piksele należące do regionów ale były to losowe piksele z 2-pikselowego otoczenia danego obiektu. Przesunięcie całego obiektu było ustalane jako uśredniony wektor wszystkich wektorów zwróconych przez algorytm *optical flow* dla otoczenia. Ponieważ nie chcieliśmy kojarzyć różnych obiektów, natomiast dopuszczaliśmy brak skojarzenia pomiędzy tymi samymi obiektami, potrzebowaliśmy silnego warunku, który stwierdzi czy skojarzone obiekty rzeczywiście są tymi samymi. Skonstruowałem go, biorąc pod uwagę wzajemne położenie obiektów oraz ich rozmiar.

Kolejnym problemem związanym również z problemem śledzenia obiektów było znajdowanie cięć w filmie. Jest to jednak problem otwarty, a ponieważ nie on był moim przedmiotem badań, cięcia wyznaczałem na podstawie korelacji sąsiednich klatek. Parametry tak dobrałem, aby dla moich danych metoda się nie myliła.

W ten sposób skonstruowałem metodę, która kojarzyła ze sobą te same obiekty z różnych klatek. Postanowiliśmy wykorzystać ją do poprawienia wyniku klasyfikacji.

Pierwszą z metod było tak zwane głosowanie. Polegała ona na tym, że dla danego obiektu sprawdzaliśmy jak został on sklasyfikowany we wszystkich klatkach i wybieraliśmy dla niego klasę, która była wybrana największą liczbą razy.

Druga metoda angażowała prosty klasyfikator online, który działał w ten sposób, że zbiór, na którym był nauczany klasyfikator był powiększany o sklasyfikowane obiekty z poprzedniej klatki. Klasyfikując w ten sposób, spodziewaliśmy się, że najlepiej sklasyfikowane będą ostatnie

obiekty w obrębie sceny. Polegając na ostatnich klatkach i wykorzystując policzone skojarzenie forsowaliśmy klasyfikacje z ostatnich klatek do poprzednich.

Innym podejściem wykorzystującym skojarzenia, było patrzenie na historie jasności w miejscach sobie odpowiadających pod względem *optical flow*. Intuicje były proste. Jeżeli występował duży skok jasności w momencie, gdy pojawił się obiekt to z dużym prawdopodobieństwem było to źródło światła albo odbicie. W przeciwnym wypadku, była to najprawdopodobniej przesycająca się tekstura.

Okazało się jednak, że intuicje stojące za powyższymi metodami nie dają wystarczająco dobrych efektów. Dwie pierwsze zmniejszały co prawda błąd naszego klasyfikatora, jednak dalej nie był on do zaakceptowania. W trzeciej metodzie okazało się, że wartości jasności są tak mocno skompresowane w interesujących nasz obszarach, że heurystyki takie nie są wystarczająco czułe.

Wszystkie eksperymenty doprowadziły nas do wniosku, że jeżeli chcemy otrzymać klasyfikację, która jest na tyle dobra, żeby zastosować ją do obróbki filmów w celach komercyjnych, musimy wprowadzić interakcje. Nie było to niczym strasznym, gdyż techniki takie są stosowane chociażby do kolorowania filmów czarno-białych. Schemat klasyfikatora, który miałby realizować takie podejście, nasuwał się sam i okazał się bardzo trafionym pomysłem, a jego opis można znaleźć w artykule. Został on przeze mnie zaimplementowany, a wraz z klasyfikatorem offline, stworzonym wcześniej, powstała pierwsza wersja interfejsu, który od tego momentu można było stosować do klasyfikowania całych wycinków filmów. W celu testowania systemu zgromadziłem ok. 10 min. fragmentów filmów, w których występowało ponad 10000 obiektów.

Mimo to, że stosując nowy system klasyfikacji mogliśmy znacznie poprawić ostateczny efekt klasyfikacji, wyniki samego klasyfikatora wciąż nie były zadowalające. Musieliśmy jednak zwolnić prace nad samym klasyfikatorem by opracować metodę do rekonstrukcji obszarów obciętych.

3.5 Rekonstrukcja obszarów cz.2

Wszystkie metody rekonstrukcji, które miały na celu zachowanie gradientów na brzegach rejonów obciętych oraz przybliżenie oryginalnego profilu zawiodły z powodu trudności w zachowaniu spójności po czasie a także tego, że wpasowywanie profili stwarzało problemy przy skomplikowanych kształtach. Postanowiliśmy stworzyć prostą metodę, która polepszy efekt wizualny, nie wprowadzając artefaktów.

Pierwszym typem artefaktów, które mogły się pojawić przy rozciąganiu kontrastu jest kwantyzacja. Drugi zaś było niezachowanie ciągłości gradientów. Zależało nam na tym aby mniejsze gradienty były mniej rozciągnięte niż duże. Wynikało to z dwóch powodów. Po pierwsze artefakty na dużych gradientach są dla człowieka mniej widoczne. Po drugie, metoda taka dawałaby profile zbliżone do oryginalnych profili, do których została zaaplikowana funkcja ludzkiego zmysłu wzrokowego (ang. human visual system response curve) .

Problem z pierwszym typem dystorsji rozwiązyaliśmy dokonując rozciągnięcia kontrastu na obrazie przefiltrowanym filtrem bilateralnym o małych wartościach parametrów. W ten sposób po pierwsze oddzielaliśmy szum, który potem jest z powrotem dodawany, po drugie zyskaliśmy na precyzji, ponieważ od tego momentu nie operowaliśmy na wartościach naturalnych ale na rzeczywistych. Problem z drugim typem dystorsji rozwiązałaby metoda gradientowa. Z takiego podejścia zrezygnowaliśmy, gdyż metoda ta jest wolna i ciężko zachować przy jej użyciu spójność czasową.

Metoda gradientowa polega na przejściu do dziedziny gradientowej i tam wykonywanie edycji obrazu. Powrót do pierwotnej dziedziny nie zawsze jest jednak prosty, gdyż obróbka mogła zakłócić własność, że w obrazie w dziedzinie gradientowej suma gradientów na dowolnej ścieżce pomiędzy dwoma punktami jest taka sama. Aby uporać się z tym problemem konieczne jest rozwiązanie równania Poissona.

Potrzebowaliśmy metody, która wprawdzie bierze pod uwagę gradienty jednak jest dużo prostsza. Na początku spróbowaliśmy odwrócić prostą metodę, mapującą tony, zaproponowaną przez G. Warda Larsona [4], opartą o analizę histogramu i sprowadzającą się do tego, że kompresowane są bardziej wartości, których jest mało w obrazie. W naszej metodzie odpowiadało by to temu, że rozciągane by były te wartości, których jest mniej w obrazie. Zaimplementowałem tę metodę. Efekt nie był taki jakiego potrzebowaliśmy, ponieważ metoda nie brała pod uwagę gradientów tylko wartości pikseli. Jednak zainspirowany przez Rafała pomysłem wykorzystania histogramu opracowałem metodę, która na podstawie gradientów, występujących w obrazie, tworzyła krzywą mapującą oryginalne wartości na nowe. Metoda, opisana w artykule, charakteryzuje się tym, że rozciąga bardziej wartości tam gdzie gradienty są duże i jest ich dużo w obrazie. Tam gdzie są małe wartości gradientów oraz jest ich mało kontrast jest rozciągany mało.

Po testach potwierdziły się nasze przypuszczenia co do tego, że powstałe profile odpowiadają tym ze studia, które postrzega człowiek. Wynikało to z tego, że największe różnice między profilami odbić a profilami światła są na brzegach regionów. Światła najczęściej mają duże gradienty na brzegach, natomiast odbicia mają łagodny profil na brzegach. Nasza metoda zachowuje te własności.

Metoda ta okazała się metodą na tyle dobrą, że została ona wykorzystana w ostatecznej wersji projektu. Jediną modyfikacją było uśrednianie liczonych histogramów po czasie dla każdego z obiektów, aby jeszcze lepiej zapewnić spójność po czasie.

3.6 Klasyfikacja cz. 3

Z powodu, że klasyfikacja nasza nie była w pełni automatyczna, tylko wymagała interakcji z użytkownikiem, podjęliśmy decyzję, że pracę przygotujemy na SIGGRAPH, a nie jak do tej pory zamierzaliśmy na CVPR. Dzięki temu zyskiwaliśmy ponad miesiąc czasu na dopracowanie wyników.

W grudniu w instytucie zostało zorganizowane spotkanie z Mattiasem Hein, który opowiadał o swoich badaniach nad klasyfikatorami. Ponieważ zainteresowało nas to o czym mówił i miało to związek z naszym projektem doszło do spotkania w wyniku, którego zgodził się nam pomóc w udoskonaleniu klasyfikatora. Po przedstawieniu mu wszystkiego co mieliśmy do tej pory oraz przygotowaniu danych Matthias zaczął prace nad naszym klasyfikatorem. Dysponując odpowiednimi narzędziami po paru spotkaniach wspólnie doszliśmy do wniosku, że musimy zastosować klasyfikator online, który będzie nauczany na obiektach z danej sekwencji (z klatek od ostatniego cięcia). Okazało się bowiem, że na statystykach, które mieliśmy, najbardziej można polegać właśnie w obszarze jednej sekwencji filmu. Natomiast w klatkach, które były pierwszymi klatkami po cięciu zastosowaliśmy *support vector machine*, dodając jeszcze dwie statystyki biorące pod uwagę otoczenie obiektu. Tak powstała ostateczna wersja klasyfikatora.

Support Vector Machine jest to metoda używana do klasyfikacji, polegająca na znalezieniu dla próbki uczącej podziału przestrzeni płaszczyznami, tak aby powstałe obszary odpowiadały klasom. Płaszczyzny są znajdowane tak, by odległość od danej płaszczyzny do najbliższej próbki z każdej z klas była możliwie największa.

3.7 Porównanie z innymi metodami

Ostatnie dwa tygodnie poświęciliśmy oprócz redagowania artykułu na porównywanie się z innymi metodami.

Naszą metodę porównaliśmy tak na prawdę tylko z jedną metodą z SIGGRAPHu z poprzedniego roku, bo tylko ta dotyczyła tego samego tematu i zajmowała się video. Po kontakcie z autorami, którzy udostępni mi część parametrów, zaimplementowałem tę metodę, przetworzyłem za jej pomocą wszystkie zgromadzone fragmenty filmów, z czego wybrałem najbardziej interesujące. W artykule zamieściliśmy także porównanie z inną metodą wykorzystującą liniowe rozciąganie, jednak ze względu na brak spójności czasowej nie było sensu porównywać całych fragmentów filmów.

3.8 Eksperyment

W celu udowodnienia, że taka obróbka zdjęć ma w ogóle sens i jest lepsza od wcześniej przedstawianych, przeprowadziłem eksperyment porównawczy na 14 osobach. Wykazał on, że obróbka taka znacznie poprawia efekty wizualne, a także, że nasza metoda jest znacznie lepsza od poprzedniej.

4 Wrażenia końcowe

Mimo początkowych wątpliwości co do przedłużenia mojego pobytu w Saarbücken w celu realizacji tego projektu, w tej chwili jestem bardzo zadowolony z podjętej decyzji. Podczas półrocznej pracy nad tym projektem wiele się nauczyłem, zdobyłem bezcenne doświadczenie a także sprezykowałem swoje zainteresowania. Pobyt ten zaważył również na moich planach na przyszłość.

4.1 Podziękowania

W tym miejscu chciałbym podziękować Karolowi Myszkowskiemu oraz Rafałowi Mantiukowi, którzy umożliwili mi realizację tego projektu, a także przekazali mi dużą wiedzę na temat dziedziny, którą się zajmuję. Dzięki nim powstała moja praca magisterska, z której jestem bardzo zadowolony. Dodatkowe podziękowania kieruję do Rafała, z którym przez pół roku pracowałem nad artykułem.

Literatura

- [1] P. Didyk, R. Mantiuk, M. Hein, H. P. Seidel: *Enhancement of Bright Video Features for HDR Displays*. To appear in: Computer Graphics Forum (Proc. of EGSR'08) 2008.
- [2] R.P.W. Duin, P. Juszczak, P. Paclik, E. Pekalska, D. de Ridder, D.M.J. Tax, S. Verzakov: *PRTools4.1, A Matlab Toolbox for Pattern Recognition, Delft University of Technology, 2007*.
- [3] Intel: *Open Source Computer Vision Library*,
<http://www.intel.com/technology/computing/opencv/>
- [4] G. Ward Larson, H. Rushmeier and C. Piatko: *A Visibility Matching Tone Reproduction Operator for High Dynamic Range Scenes, 1997*. IEEE Trans. on Vis. and Comp. Graph. 3, 4, 291-306.