

**Slovenská technická univerzita
v Bratislave
Stavebná fakulta**

**Študentská vedecká konferencia
Akademický rok 2009/2010**

Hľadanie ideálnej cesty pre kameru virtuálnej kolonoskopie

**Meno Priezvisko študenta:
Ročník a program/odbor štúdia:
Vedúci práce:
Katedra:**

**Bc. Jozef Urbán
1. ročník, 2. stupeň MPM
prof. RNDr. Karol Mikula DrSc.
Katedra matematiky a deskriptívnej
geometrie**

Bratislava 28. apríl 2010

Čestné prehlásenie

Vyhlasujem, že som túto prácu vypracoval samostatne s použitím uvedenej odbornej literatúry.

Bratislava 23. 4. 2010

.....
Vlastnoručný podpis

PodĎakovanie

Touto cestou by som sa chcel poďakovať prof. RNDr. Karolovi Mikulovi DrSc. za cenné pripomienky a odborné konzultácie a firme Tatramed spol. s r.o. za zastrešenie počas vypracovania tejto práce.

Anotácia:

Práca sa zaoberá problematikou hľadania cesty objektami v 3D obrazových dátach. Je vypracovaná v spolupráci s firmou TatraMed Bratislava. Jej výsledkom má byť vytvorenie vhodného matematického modelu a počítačového programu na hľadanie ideálnej cesty ľudským hrubým črevom, reprezentovaným obrazovou informáciou z 3D počítačovej tomografie. Táto cesta má určovať trajektóriu kamery pre virtuálnu kolonoskopiu, technológiu odboru medicíny, ktorá slúži na vyšetrenie hrubého čreva pomocou počítača. Lekár jej pomocou vyhľadáva v čreve polypy resp. nádory. Prvým krokom nami zvoleného postupu je segmentácia hrubého čreva v medicínskych dátach, na ktorú sme využili tzv. vyplňovací algoritmus. V nasledujúcich krokoch sme využili matematický model pre výpočet vzdialenostnej funkcie. Tú sme najskôr počítali vo vnútri vysegmentovaného objemu ako najkratšiu vzdialenosť k užívateľom zvolenému štartovaciemu bodu. Táto funkcia sa využije pre vytvorenie počiatočného odhadu krivky, ktorá bude reprezentovať hľadanú cestu. V ďalšom kroku sa vzdialenostná funkcia počíta ku hranici vysegmentovaného objemu. Gradient tejto funkcie určuje rýchlostné pole, do ktorého vložíme počiatočnú krivku. Projekciou rýchlostného poľa do normálovej roviny ku krivke, regularizáciou pohybu krivky vzhľadom na jej krivosť a pridaním vhodne zvolenej tangenciálnej rýchlosti dostaneme ako výsledok hladkú, asymptoticky rovnomerne rozdelenú krivku reprezentujúcu optimálnu trajektóriu pre kameru virtuálnej kolonoskopie.

Annotation:

This work deals with finding a path inside objects in 3D image data and is performed in cooperation with the company TatraMed Bratislava. The goal is to develop a suitable mathematical model and computer program for finding an ideal path in human colon represented by a visual information given by 3D computer tomography. This path will determine a trajectory of camera in virtual colonoscopy, medical technology dealing with colon diagnoses by computer. Physicians use this technology for searching polyps and tumours in colon. The first step in our approach is segmentation of the colon in medical data using a region-growing algorithm. Then we use a mathematical model for computing distance function inside the segmented volume. First we compute this function as the shortest distance to a user's selected starting point. This function is used to create an initial guess for the curve, which will represent the searched path. In the next step we calculate distance function to the boundary of segmented volume. The gradient of this function determines the velocity vector field in which we insert the initial curve. Using projection of the vector field to the plane normal to evolving curve, a regularization of the motion by curvature and suitable tangential velocity, we end up with the smooth, asymptotically uniformly discretized curve representing optimal trajectory for the camera in virtual colonoscopy.

Úvod

Kvalita života každého človeka súvisí s jeho zdravotným stavom. Ten nemusí byť vždy ideálny, ba dokonca nás často môže veľmi obmedzovať. Preto vyhľadávame nemocnice a zdravotné centrá, kde očakávame kvalitné vyšetrenie a zdravotnú starostlivosť. Po prehliadke lekár určuje diagnózu. Samotné vyšetrenia často trvajú dlho a môžu byť pre pacienta nepríjemné ba dokonca bolestivé. Na druhej strane konvenčné metódy vyšetrenia nemusia dať lekárovi dostatok informácií na presnú diagnózu. Rozvoj priemyslu a počítačovej techniky v dnešnej dobe však ponúka nové možnosti. Vďaka nim pacient absolvuje kratšie a často minimálne nepríjemné vyšetrenia a lekár ľahšie a presnejšie definuje príčinu jeho zdravotných ťažkostí.

Táto práca vznikla v spolupráci s firmou Tatramed s r.o. so sídlom v Bratislave. Firma od roku 1992 vyvíja softvérové a terapeutické systémy založené na trojrozmerné vizualizácii obrazových dát pacientov. Tie sa získajú z vyšetrení pomocou diagnostických staníc počítačovej tomografie (CT - computed tomography), magnetickej rezonancie (MR - magnetic resonance), pozitronovej emisnej tomografie (PET - positron emission tomography), angiografie a skiografie. Softvér ponúka lekárovi rôzne možnosti zobrazenia takto získaných sérií pacienta. A to od najjednoduchších ako je prezeranie jednotlivých snímok až po zložitejšie ako je volume rendering. Ďalej lekár môže pomocou jednoduchých diagnostických nástrojov v pacientových snímkach označiť dôležité miesta, napísať, či dokonca nahráť správu k danému pacientovi a takto pripraviť materiál pre jeho úspešnú liečbu. Tieto systémy sa dajú tiež využiť na segmentáciu objektov v pacientových dátach a vytváranie ich relatívne presných 3D modelov. Tie sa využívajú napríklad pri plánovaní ožarovania pacientov pri rádioterapii (určia sa objemy ktoré majú byť ožiarené a tie ktoré ožiarené nesmú byť a podľa toho sa plánujú dávky a smery ožiarenia), tiež môžu pomôcť pre vizualizáciu a pre sledovanie rastu nádorov alebo priebehu vnútorných krvácaní. Navyše pomocou systémov firmy Tatramed môže lekár diagnostikovať pacienta na počítači na úplne inom mieste napríklad aj v inej nemocnici. Keďže firma nechce zaostávať za konkurenciou, snaží sa venovať svoju pozornosť i vývoju v oblasti najnovších technológií. Preto sa rozhodla vyvinúť nástroj slúžiaci pre virtuálnu kolonoskopiu (viď nasledujúcu časť). Táto práca sa zaoberá prvou časťou tohto vývoja, t.j. hľadaním ideálnej cesty pre kameru virtuálnej kolonoskopie.

Hlavným prínosom práce má byť vytvorenie programu, ktorý tohto bude schopný. Vzhľadom na predchádzajúce práce zaoberajúce sa podobnou problematikou je tu použitých viacero nových prístupov. V prvej kapitole sa budeme zaoberať charakterizovaním vstupných dát a segmentáciou čreva v nich. V druhej časti sa zameriame na vytvorenie

počiatočnej krivky. Na to využijeme vzdialenostnú funkciu, ktorá je pre 2D spracovaná v [1]. V tomto prípade pôjde o nový prístup, pretože sa bude jednať o výpočet vzdialenostnej funkcie 3D relaxáciou Eikonalovej rovnice. Na rozdiel od [3], kde sa tiež konštruuje počiatočná krivka, spomenutú vzdialenostnú funkciu počítame len vo vysegmentovanom objeme. Získanú počiatočnú krivku vložíme do vektorového poľa. To vytvoríme opäť pomocou vzdialenostnej funkcie, ale s inak zvolenými okrajovými podmienkami. Pomocou gradientu tejto funkcie definujeme rýchlostné pole, do ktorého vložíme počiatočnú krivku. Pohybom 2D kriviek vo vhodne zvolenom rýchlostnom poli sa zaoberajú napríklad autori v [2], [6]. V tejto práci sa budeme venovať pohybu 3D kriviek, ktorý má oproti 2D určité špecifiká. Jadrom práce je kapitola nazvaná Optimálna 3D krivka. Prezentujeme v nej podobné modifikácie rýchlostného poľa ako sú uvedené v [4],[7],[8],[9], kde sa pracuje len v 2D oblasti. Rýchlostné pole projektujeme do roviny normálovej ku krivke, krivku regularizujeme pomocou krivosti a navrhujeme tangenciálnu redistribúciu bodov diskretnej krivky. Pri návrhu vhodnej tangenciálnej rýchlosti sme potrebovali zostrojiť novú otonormálnu bázu. Pri jej konštrukcii sme sa nechali inšpirovať článkom [5]. Prístupy, prezentované v tejto časti sú nové a originálne. Na záver zhodnotíme dosiahnuté výsledky.

Virtuálna kolonoskopia

Rakovina hrubého čreva je podľa oficiálnych údajov z roku 2007 v štátoch začlenených do Svetovej zdravotníckej organizácie po rakovine prsníka a pľúc treťou najčastejšou. Najrizikovejšou skupinou sú ľudia starší ako 50 rokov, diabetici, obézni ľudia, ľudia trpiaci nezhubnými ochoreniami hrubého čreva, ženy, ktoré prekonalí alebo majú rakovinu prsníka, vaječníkov alebo maternice resp. ľudia, ktorým v rodine diagnostikovali kolorektálny karcinóm. Ak je však táto rakovina včas objavená, dá sa úspešne liečiť.

Kolonoskopia je vyšetrenie hrubého čreva, ktoré v čreve dokáže úspešne odhaliť polypy a kolorektálne karcinómy. Samotné vyšetrenie trvá od 15 minút do hodiny. Pri tomto vyšetrení sa používa kolonoskop (prístroj, ktorý sa skladá z hadice, má zabudovanú miniatúrnu kameru, prípadne nástroj na odoberanie tkaniva). Pacient pred vyšetrením musí dodržať predpísanú diétu (zniži príjem potravy, musí prijímať dostatočné množstvo tekutín, tri dni pred zákrokom prijíma len kašovitú stravu, deň pred vyšetrením len tekutiny a prehľadnú, aby mal hrubé črevo v čase vyšetrenia prázdne. Počas vyšetrenia sa zavádza kolonoskop cez konečník do hrubého čreva. Črevom postupuje až po jeho začiatok. Lekár na obrazovke vidí vďaka kamere kolonoskopu situáciu v samotnom čreve. Keďže je toto vyšetrenie nepríjemné a bolestivé, pacient pred jeho začiatkom dostane lieky tlmiace bolesť. Niektorí pacienti absolvujú toto vyšetrenie pod celkovou anestéziou. Podľa skúseností lekárov, len malé percento pacientov je ochotné opakovane dobrovoľne podstúpiť toto vyšetrenie a radšej sa vystavia riziku neliečenej rakoviny a pod.

Pri virtuálnej kolonoskopii ide o neinvazívne vyšetrenie použitím počítačovej tomografie. Príprava pacienta je podobná ako pri klasickom vyšetrení. Večer pred ním ale musí vypíť kontrastný roztok. Tým sa obalia všetky zvyšky stolice v čreve, čo bude vidno na snímkach z CT resp. dajú sa jednoducho odfiltrovať. Pred vyšetrením sa pacientovi nafúkne (vzduchom alebo CO₂) hrubé črevo. Potom sa pacient oskenuje v dvoch polohách (na bruchu a na chrbte) pomocou počítačovej tomografie. Pacientova úloha v

tomto okamihu končí. Na rad prichádza špeciálny program, ktorý zo snímok zostaví 3D model čreva, ktorý sa dá prezerať podobne ako obraz pri klasickej kolonoskopii. Kameru virtuálnej kolonoskopie môže lekár sám ovládať, natáčať ako aj spustiť automatickú prehliadku čreva, kde kamera putuje po vypočítanej ideálnej trajektórii. Výsledky dosiahnuté virtuálnou kolonoskopiou sú porovnateľné s klasickým prístupom. Lekár si navyše snímky môže prezerať kedykoľvek a tak dlho ako potrebuje. Niektoré softvéry poskytujúce virtuálnu kolonoskopiu dávajú možnosť prezerania panorámy čreva. Ide o virtuálne rozrezanie a rozbalenie čreva. V takomto zobrazení má lekár možnosť iným spôsobom sledovať štruktúru čreva. Okrem týchto prínosov, ponúka virtuálna kolonoskopia oproti klasickej i možnosť vyšetrenia pacientov, ktorí nemôžu absolvovať vyšetrenie bežným prístupom, napríklad z dôvodu, že majú pre kolonoskop nepriechodné črevo. Ďalšou výhodou oproti klasickému prístupu je, že pacient je minimálne zaťažovaný samotným vyšetrením. Nevýhodou je ožiarenie, ktoré pacient počas vyšetrenia na CT prijme. Jeho dávka závisí od kvality a rýchlosti CT prístroja. Vo všeobecnosti je však neškodná. Pacient tiež môže byť alergický na podávanú kontrastnú látku, čo sa však dá vopred zistiť. Hlavnou nevýhodou ostáva fakt, že pokiaľ lekár v čreve nájde polyp alebo nádor, nemôže ho týmto virtuálnym prístupom odobrať.

Ciele práce

Cieľom tejto práce je vytvorenie matematického modelu a počítačového programu na automatické nájdenie ideálnej cesty pre kameru virtuálnej kolonoskopie. S tým je spojené osvojenie si problematiky pohybujúcich sa 3D kriviek z matematického ako aj numerického hľadiska. Predpokladá sa použitie medicínskych obrazových údajov z CT. Užívateľ zadá počiatočný bod cesty na konci hrubého čreva, t.j. v oblasti konečníka, a program na základe obrazovej informácie vypočíta ideálnu cestu črevom až po jeho začiatok. Pod ideálnou cestou rozumieme krivku, ktorá prechádza približne stredom čreva, je hladká a diskkrétne body, ktoré ju tvoria sú na nej rovnomerne rozložené. Pokúsime sa to docieľiť viacerými spôsobmi, pričom výsledky na záver porovnáme. Pri práci a implementácii budeme využívať programovací jazyk C++ vo vývojovom prostredí MS Visual Studio 2008. Na analýzu výsledkov použijeme softvéry Mathematica a ParaView.


Kapitola 1

Segmentácia

V tejto kapitole budeme hovoriť o prvom kroku nášho snaženia, o segmentácii. V prvom rade od nej závisí kvalita dosiahnutého výsledku. Tá je úzko spojená so vstupnými dátami, preto ich v úvode tejto kapitoly stručne opíšeme.

1.1 Vstupné dáta

Vstupom pre vytváranú aplikáciu budú trojrozmerné binárne zapísané *.raw súbory. Presne také súbory aké sa získavajú z CT modalít. Tieto modalitty určujú na základe absorpcie röntgenového žiarenia látkou, ktorou prechádzajú, hustotu tkanív v jednotlivých rezoch pacienta. Táto hustota má jednotku Hounsfield (HU). Jej rozsah je od -1024 (vzduch) do 3071 (kosti). Tieto hodnoty sú však vo vstupných súboroch lineárne rozťahnuté do rozsahu pre dátový typ unsigned short (t.j. od 0 do 65535). Zapísané sú hneď za hlavičkou súboru, v ktorej sa určujú okrem iného i rozmery dát. Keďže bolo žiaduce tieto dáta nejakým rozumným spôsobom zobrazíť užívateľovi, museli sme ich pre vykreslenie transformovať. Dáta, ktoré sme potrebovali vidieť sú v HU v rozsahu od -1000 do 1000 . Preto sme patrične orezali originálne dáta a lineárne sme ich pretransformovali do rozsahu pre bitmapy (0 až 255). Túto transformáciu sme robili len kvôli zobrazeniu. Originálne dáta sme zachovali nezmenené, pretože by sme z nich takto mohli stratiť potrebné informácie pre segmentáciu. V predloženej práci budeme naše priebežné výsledky a postupy prezentovať predovšetkým na testovacích obrázkoch. Pre názornosť a jednoduchšiu predstavu si jednotlivé prípady ukážeme najskôr v 2D a potom analogicky v 3D. Pre 2D prípad sme vytvorili testovací obrázok pripomínajúci zjednodušený tvar čreva. Pre 3D to je zas útvar pripomínajúci otočené písmeno U.




Obrázok 1.1: Testovacie dáta

1.2 Vyplňovací algoritmus

Na segmentáciu sme použili mierne modifikované riadkové semienkové vyplňovanie (scan-line seed fill). Inšpiráciu sme čerpali z popisu v [10]. Všetky body oblasti okrem svojej súradnice vlastnia príslušnú číselnú informáciu z originálnych dát a stav, či sú vyplnené alebo nevyplnené. Na rozbehnutie algoritmu potrebujeme ešte dve informácie. Jednak je to počiatočný vnútorný bod segmentovanej oblasti tzv. semienko, od ktorého sa začne oblasť vyplňať a na druhej strane podmienku, podľa ktorej sa rozhoduje, či sa stav skúmaného bodu nastaví na vyplnený. Môže to byť napríklad rozsah hodnôt určený na základe semienka, do ktorého musí spadať. Pre jednoduchosť opisu popíšeme algoritmus v 2D. Uvažujme 4-smerovo súvislú oblasť, to znamená, že zo semienka sa môžeme pohybovať len vo vodorovnom a zvislom smere. V prvom kroku otestujeme suseda nad a pod semienkom. Ak niektorý z nich spĺňa určené kritérium (a nie je vyplnený), pridáme ho do zoznamu semienok. Tiež sa nastaví prepínač up, resp down na hodnotu TRUE, že bol do zoznamu pridaný horný resp. dolný sused. Ďalej pokračujeme v testovaní susedov smerom doľava. Ak testovaný sused vyhovuje kritériu, nastavíme jeho stav na vyplnený. Zároveň testujeme, jeho susedov zhora a zdola. Ak horný sused nespĺňa podmienku, znamená to, že v tomto bode je hrana a prepínač up nastavíme na FALSE. Ak však spĺňa podmienku, a prepínač up je nastavený na TRUE, budeme ho ignorovať, pretože v zozname semienok je už semienko z riadku tohto suseda a medzi nimi nie je hrana. Ak je up FALSE, nastavíme ho na TRUE a suseda pridáme do zoznamu semienok rovnako ako v prvom kroku. Podobne postupujeme v prípade dolného suseda. Testovanie smerom doľava pokračuje kým nenarazíme na ľavého suseda, ktorý nespĺňa požadované kritérium. Vtedy nastavíme up aj down na hodnotu FALSE a rovnaký postup vykonáme aj smerom doprava od počiatočného semienka. Keď sa práca na počiatočnom riadku ukončí, ďalšie semienka vyberáme postupne zo zoznamu semienok a podľa už opísaného postupu doň ďalšie dopĺňame. Algoritmus beží až kým sa nevyprázdni zoznam semienok. Pre 3D prípad je postup podobný, len uvažujeme 6-smerovo súvislú oblasť, kde nám pribudne sledovanie susedov aj smerom dopredu a dozadu.

Na obr. 1.2 vidíme výsledok segmentácie v jednom reze dosiahnutý vytvorenou aplikáciou. Užívateľ zadal ako počiatočné semienko bod vnútri čreva a určil toleranciu.



Obrázok 1.2: Zobrazené vstupné dáta pred a po segmentácii hrubého čreva

Popísaný algoritmus vyplnil vzduchom nafúknutý objem čreva. Podmienkou presnej segmentácie je okrem kvality vstupných dát vhodne zvolená tolerancia a to, či je črevo úplne vyprázdnené. Existujú však algoritmy, ktoré dokážu z čreva odstrániť i nechcenú tekutinu ba dokonca i zvyšky stolice.

Kapitola 2

Vzdialenostná funkcia

V predchádzajúcej časti sme úspešne vysegmentovali oblasť, cez ktorú má viesť cesta kamery pre virtuálnu kolonoskopiu. Skôr ako začneme tvarovať hľadanú cestu, musíme navrhnuť počiatočný tvar krivky, ktorá ju bude reprezentovať. Ďalej budeme potrebovať navrhnuť rýchlostné pole, ktoré bude hlavnou hybnou silou krivky a bude prispievať k tomu, aby výsledná cesta ležala približne v strede čreva. Na dosiahnutie obidvoch spomenutých cieľov sme využili vzdialenostnú funkciu. Jej návrh a výpočet je podrobne opísaný pre 2D prípad v článku [1]. My uvedieme jej výpočet pre 3D prípad.

Označme hľadané riešenie vzdialenostnej funkcie ako d . To získame riešením Eikonalovej diferenciálnej rovnice

$$d_t + |\nabla d| = 1. \quad (2.1)$$

Výpočtovou oblasťou je vnútro vysegmentovaného objemu. Pred samotným výpočtom určíme okraj oblasti. Sú to tie vysegmentované body, ktoré ležia na prechode medzi vyplneným a nevyplneným objemom. Okrajové podmienky určíme podľa toho, akú vzdialenosť má počítaná funkcia predstavovať. Budeme sa tomu venovať o trochu neskôr. Rovnica (2.1) môže byť diskretizovaná podľa Rouy-Tourinovej schémy. Označme d_{ijk}^n približnú hodnotu riešenia d v časovom kroku n v strede voxela s priestorovou súradnicou (i, j, k) , τ_D dĺžku časového kroku, h_D dĺžku hrany voxela. Ďalej definujme funkciu M_{ijk}^{pqr} , kde $p, q, r \in \{-1, 0, 1\}$, $|p| + |q| + |r| = 1$ ako

$$M_{ijk}^{pqr} = (\min(d_{i+p, j+q, k+r}^n - d_{ijk}^n, 0))^2. \quad (2.2)$$

Rouy-Tourinovu schému pre (2.1) potom môžeme napísať ako


$$d_{ijk}^{n+1} = d_{ijk}^n + \tau_D - \frac{\tau_D}{h_D} \sqrt{\max(M_{ijk}^{-1,0,0}, M_{ijk}^{1,0,0}) + \max(M_{ijk}^{0,-1,0}, M_{ijk}^{0,1,0}) + \max(M_{ijk}^{0,0,-1}, M_{ijk}^{0,0,1})}. \quad (2.3)$$

Ako vidno z numerickej schémy, na hodnotu vzdialenostnej funkcie vplyvajú hodnoty v susedných bodoch. Algoritmus funguje tak, že na začiatku zafixujeme na nulu (resp. nastavíme vhodné okrajové podmienky) hodnoty v bodoch, ku ktorým chceme počítať vzdialenosť a iteratívne ju počítame vo všetkých ostatných bodoch vysegmentovaného objemu dovtedy, kým model neskonverguje k vzdialenosti približne rovnej skutočnej. Algoritmus sa dá urýchliť rôznymi spôsobmi. Napríklad tak, že na začiatku v celom objeme

namiesto nuly nastavíme najmenšiu vzdialenosť medzi stredmi dvoch susedných voxelov. Tiež je možné fixovať priebežne hodnoty v tých bodoch, ktoré sa už nemenia. O urýchlení algoritmu sa viac píše v [1].


2.1 Konštrukcia počiatocnej krivky

Pri konštrukcii počiatocnej krivky sme sa nechali inšpirovať článkom [3]. Na jej konštrukciu potrebujeme zadať štartovací bod, v ktorom bude začínať hľadaná cesta. Predpokladáme, že sa nachádza niekde na konci čreva, t.j. v oblasti konečníka. Ak v tomto bode zafixujeme hodnotu vzdialenostnej funkcie na nulu, a v hraničných bodoch vysegmentovaného objemu ju nastavíme v každom iteračnom kroku napríklad na priemer hodnôt v jeho susedných vnútorných bodoch, dostaneme po výpočte (2.3) v celom objeme reálne vzdialenosti k počiatocnému bodu. Keďže vieme, že črevo je podlhovastý útvar, ktorý má dĺžku omnoho väčšiu ako prierez, môžeme za približný začiatok čreva vyhlásiť bod s najväčšou vzdialenosťou k štartovaciemu. Je to približne oblasť v ktorej ústi tenké črevo do hrubého. Ak sa potom vrátíme z tohto globálneho maxima cestou cez najväčší spád, t.j. najväčšej absolútnej hodnoty gradientu, dostaneme sa až na koniec čreva, teda do štartovacieho bodu. Cesta, ktorá bola týmto spôsobom prekonaná bude predstavovať počiatocnú krivku. Na nasledujúcich obrázkoch vidíme vypočítané vzdialenostné funkcie ako i získané počiatocné krivky.




Obrázok 2.1: Graf vzdialenostnej funkcie pre 2D dáta zobrazený v 3D a v 2D spolu s počiatocnou krivkou

Z obrázkov je zrejmé, že počiatocná krivka prechádza celým črevom. Je však zrejmé, že nespĺňa požiadavky na ideálnu cestu. Nie je ani hladká, ani nejde stredom čreva. Naopak, je viackrát zalomená a ťahá sa často po stene čreva.



Obrázok 2.2: Graf vzdialenostnej funkcie pre 3D dáta zobrazený v 2D reze a 3D počiatočná krivka vo vysegmentovanom objeme




Obrázok 2.3: Vysegmentované črevo s počiatočnou cestou


2.2 Konštrukcia vhodného rýchlostného poľa

V tretej kapitole sa budeme venovať pohybu krivky v rýchlostnom poli. V tejto časti toto vektorové pole navrhujeme. Opäť využijeme numerickú schému (2.3) pre vzdialenostnú funkciu. Tentokrát však nebude predstavovať vzdialenosť od jedného bodu, ale vzdialenosť k najbližšiemu okraju vysegmentovaného objemu. To znamená, že tentokrát budeme riešiť úlohu s nulovými Dirichletovými okrajovými podmienkami na hranici vysegmentovanej oblasti. Teda, na hranici bude hodnota vzdialenostnej funkcie fixovaná počas celého výpočtu na nulu. Na nasledujúcich obrázkoch vidíme vypočítané vzdialenostné funkcie pre testovacie obrázky.

Samotné vektorové pole dostaneme ako gradient tejto vzdialenostnej funkcie. Teda



Obrázok 2.4: Graf vzdialenostnej funkcie počítanej od hranice pre 2D dáta zobrazený v 2D a detail zobrazenia v 3D




Obrázok 2.5: Graf vzdialenostnej funkcie počítanej od hranice pre 3D dáta zobrazený v 2D reze

$$\mathbf{v}(x, y, z) = \nabla d(x, y, z) = \left(\frac{\partial d}{\partial x}, \frac{\partial d}{\partial y}, \frac{\partial d}{\partial z} \right)^T. \quad (2.4)$$

Gradient budeme počítat numerickou aproximáciou centrálnou diferenciou

$$\mathbf{v}_{ijk} = \left(\frac{d_{i+1jk} - d_{i-1jk}}{2h}, \frac{d_{ij+1k} - d_{ij-1k}}{2h}, \frac{d_{ijk+1} - d_{ijk-1}}{2h} \right). \quad (2.5)$$

Týmto spôsobom získame rýchlostné pole smerujúce ku "hrebeňu" vzdialenostnej funkcie. Práve naň chceme dostať našu počiatočnú krivku. Toto pole je najdôležitejšou informáciou pre modely uvedené v nasledujúcej kapitole. Na základe neho nájdeme ideálnu trajektóriu pre kameru virtuálnej kolonoskopie.



Obrázok 2.6: Znázornenie detailu vektorového poľa vypočítaného na 2D dátach

Kapitola 3

Optimálna 3D trajektória

V predchádzajúcej časti sme navrhli a vytvorili počiatočnú krivku. V tejto kapitole z nej vymodelujeme ideálnu cestu vysegmentovaným objemom. Na tento účel využijeme predovšetkým navrhnuté rýchlostné pole. To bude hlavnou hybnou silou krivky. V tejto kapitole budeme okrem iného prezentovať rôzne modifikácie tohto rýchlostného poľa a ich vplyv na výslednú krivku. Pohybom 2D kriviek riadeným vhodne zvoleným rýchlostným poľom sa zaoberajú [2],[6],[9].

3.1 Krivka v rýchlostnom poli


Krivka bude reprezentovaná bodmi. Tie budeme označovať ich polohovými vektormi $\mathbf{r}_i^n$, kde i označuje poradie bodu krivky a n časový krok pohybu, pričom nultý a m -tý bod považujeme za fixovaný. Najjednoduchší pohyb krivky môžeme popísať nasledovne

$$\partial_t \mathbf{r} = \mathbf{v}. \quad (3.1)$$

Ide vlastne o pohyb bodov zapríčinený len rýchlostným poľom. Novú pozíciu bodu teda dostaneme pomocou nasledujúceho vzťahu

$$\mathbf{r}_i^{n+1} = \mathbf{r}_i^n + \tau \mathbf{v}, \quad (3.2)$$

kde τ predstavuje zvolený časový krok. Na obr. 3.1 vidíme výsledky dosiahnuté týmto prístupom. Jasne je vidno vplyv rýchlostného poľa na pohybujúce sa body. Krivky sa pohlí ku stredu vysegmentovaného objemu. Body krivky nie sú žiadnym spôsobom zviazané ani regularizované. Najviac je to vidno v 2D prípade, kde vektorové pole zhlukuje body do skupín v stredoch jednotlivých krúžkov. Z tohto dôvodu krivky nie sú hladké. Tento problém bude treba riešiť.



Obrázok 3.1: Výsledky dosiahnuté len vplyvom rýchlostného poľa pre 2D a 3D dáta

3.2 Normálová rýchlosť a krivosť

Ako sme spomenuli v predchádzajúcej časti, chceme nejakým spôsobom docieľiť, aby body pohybovanej krivky boli nejakým spôsobom zviazané, aby sa nezhlukovali do skupín a aby bola krivka hladká. Momentálny model totiž tieto požiadavky nespĺňa a preto je nepoužiteľný pre zložitejšie štruktúry akou je napríklad hrubé črevo. Medzi spomenutými skupinami bodov môže byť veľká vzdialenosť a teda nie je zaručené, že medzi nimi nie je stena čрева, na ktorú by sme tým pádom mohli naraziť. Pozitívom prvotného modelu však je, že rýchlostné pole detekuje stred vysegmentovaného objemu. Pohyb krivky vo všeobecnosti môžeme rozložiť na pohyb v smere tangenty a normály. Ako je uvedené aj v [9], ak je diskretná krivka dostatočne jemne delená, jej tvar nezáleží od tangenciálnej zložky rýchlosti. Tá má vplyv len na rozloženie bodov na krivke, ktoré je momentálne nevhodné. Tvar krivky určuje normálová zložka rýchlosti. V tejto časti nevhodnú tangenciálnu zložku pohybu zanedbáme. Pohyb krivky do normálovej roviny ku krivke v 3D definujeme ako


$$\partial_t \mathbf{r} = \mu \mathbf{N}_v + \epsilon k \mathbf{N}, \quad (3.3)$$

kde $\mathbf{N}_v$ predstavuje rýchlosť projektovanú do normálovej roviny, $\mathbf{N}$ predstavuje jednotkový normálový vektor 3D krivky, μ a ϵ sú parametre. Vektor $\mathbf{T}$ na obr (3.2) predstavuje jednotkový tangenciálny vektor ku krivke a $\mathbf{v}$ vektor rýchlostného poľa. Projekciou rýchlosti do vektora $\mathbf{T}$ násobenou $\mathbf{T}$ dostaneme $\mathbf{T}_v = (\mathbf{T} \cdot \mathbf{v}) \mathbf{T}$. Vektor projektovaný do normálovej roviny ku krivke následne dostaneme ako rozdiel $\mathbf{N}_v = \mathbf{v} - \mathbf{T}_v$. Člen $k \mathbf{N}$ uvedený v (3.3) predstavuje vektor krivosti počítaný podľa schémy z [9]

$$k_i^n \mathbf{N}_i^n \approx \frac{2}{h_{i+1}^n + h_i^n} \left(\frac{\mathbf{r}_{i+1}^n - \mathbf{r}_i^n}{h_{i+1}^n} - \frac{\mathbf{r}_i^n - \mathbf{r}_{i-1}^n}{h_i^n} \right) \quad i = 1, 2, \dots, m-1. \quad (3.4)$$

Celé číslo m označuje počet bodov počítanej krivky a i je poradové číslo bodu. Na výpočet vzdialeností susedných uzlov h_i v časovom okamihu n použijeme vzťah

$$h_i^n = \sqrt{(x_i^n - x_{i-1}^n)^2 + (y_i^n - y_{i-1}^n)^2 + (z_i^n - z_{i-1}^n)^2}, \quad \text{kde } \mathbf{r}_i^n = (x_i^n, y_i^n, z_i^n). \quad (3.5)$$




Obrázok 3.2: Projekcie rýchlostného poľa do roviny normálovej ku krivke

Rovnicu (3.3) potom môžeme prepísať ako

$$\frac{\mathbf{r}_i^{n+1} - \mathbf{r}_i^n}{\tau} = \mu (\mathbf{N}_v)_i^n + \epsilon \frac{2}{h_{i+1}^n + h_i^n} \left(\frac{\mathbf{r}_{i+1}^n - \mathbf{r}_i^n}{h_{i+1}^n} - \frac{\mathbf{r}_i^n - \mathbf{r}_{i-1}^n}{h_i^n} \right). \quad (3.6)$$

Týmto modelom odstránime nevhodný tangenciálny pohyb bodov krivky. Krivostný člen navyše prináša citlivosť pohybu bodov na vzdialenosť od susedov a tak ich navzájom zväzuje. Krivka získaná týmto modelom má regulárnejšie rozloženie bodov ako pri predchádzajúcom postupe a je takisto umiestnená približne v strede vysegmentovaného objemu. Výsledky dosiahnuté na testovacích dátach sú zobrazené na obr. 3.3. Ako vidíme, vý-



Obrázok 3.3: Výsledky dosiahnuté projekciou do normálovej roviny a krivosťou na 2D a 3D dátach

sledky sú lepšie ako po použití prvého modelu. Vidíme však aj voľným okom, že body krivky sú stále nerovnomerne rozmiestnené. To môže spôsobiť pri zložitejších štruktúrach

nesprávny pohyb krivky v rýchlostnom poli. Ak chceme, aby tvar krivky čo najlepšie vystihoval hrebeň vzdialenostnej funkcie, musí byť táto krivka čo najrovnomernejšie rozdelená. To dosiahneme pridaním vhodne zvolenej tangenciálnej rýchlosti do modelu. Tá zabezpečí rovnomernú redistribúciu bodov krivky.

3.3 Asymptoticky rovnomerná redistribúcia

V 3D prípade nemôžeme priamočiaro zovšeobecniť 2D prístup pre tangenciálnu redistribúciu zavedenú v [7],[8]. Dôvodom je fakt, že nevieme definovať krivosť ako skalár so znamienkom. Takisto Frenetov trojhran má singulárne správanie v bodoch, kde je vektor krivosti $k\mathbf{N}$ rovný nule. Preto zavedieme inú ortogonálnu bázu, ktorej správanie bude pozdĺž krivky hladké. Takýto postup bol realizovaný v [5]. Tangenciálna redistribúcia tam bola vytvorená pre tzv. $k_1 - k_2 - \omega - L$ formuláciu pohybu 3D krivky. My túto tangenciálnu redistribúciu zovšeobecníme na asymptoticky rovnomernú, pričom uvažujeme štandardnú formuláciu pre evolúciu pozičného vektora $\mathbf{r}$ 3D krivky.

Našu novú bázu bude tvoriť $\mathbf{T}$, t.j. jednotkový tangenciálny vektor krivky, a dva vektory ležiace v normálovej rovine ku krivke definované ako $\mathbf{N}_1 = \frac{\mathbf{N}_v}{|\mathbf{N}_v|}$ a $\mathbf{N}_2 = \mathbf{N}_1 \times \mathbf{T}$. Takáto konštrukcia zodpovedá $\mathbf{N}_1$ a $\mathbf{N}_2$ z [5] pre hladkú rotáciu bázy ω v prípade hladkého vektorového poľa $\mathbf{N}_v$. V prípade, ak $|\mathbf{N}_v| = 0$, dodefinujeme $\mathbf{N}_1$ a $\mathbf{N}_2$ tak, aby spĺňali podmienku hladkosti rotácie ortogonálnej sústavy (v diskretnom tvare napríklad ako priemer zo susedných bodov krivky). Ďalej definujeme k_1 a k_2 ako projekcie vektora krivosti do $\mathbf{N}_1$ a $\mathbf{N}_2$. Inak povedané $k_1 = k\mathbf{N} \cdot \mathbf{N}_1$ a $k_2 = -k\mathbf{N} \cdot \mathbf{N}_2$. A teda pre vektor krivosti platí

$$k\mathbf{N} = k_1\mathbf{N}_1 - k_2\mathbf{N}_2. \quad (3.7)$$

V [5] autori uvádzajú rozklad pohybu krivky do ortonormálnej bázy ako

$$\partial_t \mathbf{r} = U\mathbf{N}_1 + V\mathbf{N}_2 + \alpha\mathbf{T}, \quad (3.8)$$

kde α je tangenciálna komponenta pohybu a U resp. V sú normálové komponenty, vypočítané vzťahmi

$$U = k_1 - |\mathbf{N}_v| \quad (3.9)$$

$$V = -k_2. \quad (3.10)$$

Nech krivka Γ je parametrizovaná funkciou pozičného vektora $\mathbf{r}$. Definujme veličinu určujúcu lokálnu dĺžku $g = |\frac{\partial \mathbf{r}}{\partial u}| \approx \frac{\mathbf{r}_i - \mathbf{r}_{i-1}}{h}$, $u \in S^1$, pričom $h = \frac{1}{m}$ predstavuje rovnomerné delenie S^1 . Z článku [5] vyplýva, že pre 3D krivku platí

$$\partial_t g = g\partial_s \alpha - g(Uk_1 - Vk_2). \quad (3.11)$$

Z toho dostaneme

$$\frac{dL}{dt} = - \langle Uk_1 - Vk_2 \rangle_\Gamma L, \quad (3.12)$$

kde L je celková dĺžka krivky Γ . Strednú hodnotu $\langle Uk_1 - Vk_2 \rangle_\Gamma$ budeme aproximovať ako

$$\langle Uk_1 - Vk_2 \rangle_\Gamma \approx \frac{1}{L^n} \sum_{l=1}^m h_l^n (U_l^n k_{1l}^n - V_l^n k_{2l}^n). \quad (3.13)$$

Aby sme odvodili asymptoticky rovnomernú redistribúciu bodov krivky, zaujímavý je pre nás podiel

$$\frac{g}{L} \approx \frac{|\mathbf{r}_i - \mathbf{r}_{i-1}|}{Lh} = \frac{|\mathbf{r}_i - \mathbf{r}_{i-1}|}{\left(\frac{L}{m}\right)} = \frac{h_i}{\left(\frac{L}{m}\right)}. \quad (3.14)$$

Ten predstavuje pomer lokálnej dĺžky delenia krivky a priemernej dĺžky jej delenia. Ak sa podiel rovná 1, dosiahli sme rovnomernú redistribúciu. Označme

$$\theta = \ln \left(\frac{g}{L} \right). \quad (3.15)$$

Cieľom je, aby sa asymptoticky $\theta = 0$. Keďže platí

$$\partial_t \theta = \partial_t \left[\ln \left(\frac{g}{L} \right) \right] = \frac{L}{g} \frac{\partial_t g L - g \partial_t L}{L^2}, \quad (3.16)$$

po dosadení (3.11) a (3.12) do (3.16) dostaneme

$$\partial_t \theta = \partial_s \alpha - Uk_1 + Vk_2 + \langle Uk_1 - Vk_2 \rangle_\Gamma. \quad (3.17)$$


Keďže chceme, aby $\theta \rightarrow 0$ pre $t \rightarrow \infty$, zvolíme ju napríklad takú, že spĺňa diferenciálnu rovnicu $\partial_t \theta = (e^{-\theta} - 1)\omega_r$, kde ω_r je rýchlosť priebehu redistribúcie. Pravá strana vzťahu (3.15) sa zjednoduší a dostaneme $e^{-\ln(\frac{g}{L})} - 1 = e^{\ln(\frac{L}{g})} - 1 = \frac{L}{g} - 1$ a teda z (3.17) dostaneme vzťah pre tangenciálnu rýchlosť α . Tou dosiahneme asymptoticky rovnomernú redistribúciu bodov krivky, ak

$$\partial_s \alpha = Uk_1 - Vk_2 - \langle Uk_1 - Vk_2 \rangle_\Gamma + \left(\frac{L}{g} - 1 \right) \omega_r. \quad (3.18)$$

Keďže platí $\mathbf{T} = \partial_s \mathbf{r}$, môžeme výsledný model aj s tangenciálnou zložkou rýchlosti zapísať ako

$$\partial_t \mathbf{r} = \mu \mathbf{N}_v + \epsilon \partial_{ss} \mathbf{r} + \alpha \partial_s \mathbf{r}. \quad (3.19)$$

Výsledky dosiahnuté týmto prístupom na testovacích dátach sú zobrazené na obr. 3.4. Vidíme, že body krivky sú rovnomerne rozdelené a krivka spĺňa všetky stanovené požiadavky. Našli sme teda vhodný model pre ideálnu cestu kamery virtuálnej kolonoskopie.




Obrázok 3.4: Výsledky dosiahnuté výsledným modelom na 2D a 3D dátach

Kapitola 4


Dosiahnuté výsledky

V predchádzajúcich kapitolách sme hľadali krivku, ktorá by mohla predstavovať ideálnu cestu pre kameru virtuálnej kolonoskopie. Videli sme, ako sa naše výsledky postupne zlepšovali. Mohli sme pozorovať, aký vplyv na krivku má rýchlostné pole a prečo je dobré ho modifikovať. Záverečným modelom (3.19) sme dosiahli vizuálne najlepšie výsledky. Nielen čo sa týka tvaru ale hlavne rozloženia bodov na krivke. Číselné porovnanie redistribúcie bodov krivky poskytujú nasledujúce obrázky. Na grafoch vidíme vplyv modelov na redistribúciu bodov. Porovnáваме model (3.1) (zelená farba), model (3.3) (modrá farba) a model (3.19). Na grafoch sú znázornené vzdialenosti susedných bodov pre 2D a 3D testovacie dáta. Krivky dosiahnuté posledným modelom majú vhodné vlastnosti




Obrázok 4.1: Porovnanie redistribúcie bodov v jednotlivých modeloch pre testovacie 2D a 3D dáta

aby tvorili trajektóriu kamery pre virtuálnu kolonoskopiu. Na nasledujúcich obrázkoch sú znázornené výsledky dosiahnuté na ďalších testovacích dátach (špirála) a na dátach reálneho pacienta.



Obrázok 4.2: Počiatočná a výsledná krivka nájdená v 3D špirále.



Obrázok 4.3: Výsledky dosiahnuté na reálnych dátach

4.1 Ciele do budúcnosti

Čo sa týka predstaveného modelu a s ním súvisiacej aplikácie, v budúcnosti by sme radi doplnili a vylepšili jej vlastnosti. Uvedený model v našej aplikácii riešime explicitnou schémou, s ktorou súvisia podmienky na stabilitu. Preto by sme radi stabilizovali výpočet napríklad semiimplicitným prístupom. Ďalej by sme chceli vylepšiť spomínanú segmentáciu tak, aby dokázala z čreva odfiltrovať prípadné zvyšky tekutín. Najzaujímavejším vylepšením by však bolo, keby aplikácia sama dokázala určiť štartovací bod na konci čreva. Možný prístup by bol napríklad rozoznávaním tvaru rúrky, pomocou ktorej sa pacientovo črevo nafukuje. Táto rúrka je jasne vidno v snímkach získaných z CT.

Literatúra

- [1] P.Bourgine, P.Frolkovic, K.Mikula, N.Peyrieras, M.Remesikova, *Extraction of the intercellular skeleton from 2D microscope images of early embryogenesis*, in Lecture Notes in Computer Science 5567 (Proceeding of the 2nd International Conference on Scale Space and Variational Methods in Computer Vision, Voss, Norway, June 1-5,2009), Springer (2009).
- [2] V. Caselles, R. Kimmel, G. Sapiro, *Geodesic active contours*, International Journal of Computer Vision, 22 (1997), pp. 61–79.
- [3] T. Deschamps, *Curve and Shape Extraction with Minimal Path and Level-Sets techniques: Applications to 3D Medical Imaging*. PhD dissertation, University of Paris Dauphine, 2001.
- [4] G. Dziuk, *Convergence of a semi discrete scheme for the curve shortening flow*, Mathematical Models and Methods in Applied Sciences, 4 (1994), pp. 589–606.
- [5] T. Y. Hou, I. Klapper and H. Si, *Removing the Stiffness of Curvature in Computing 3-D Filaments*, J. Comput. Phys. , 143 , 628-664 (1998).
- [6] S. Kichenassamy, A. Kumar, P. Olver, A. Tannenbaum, A. Yezzi, *Conformal curvature flows: from phase transitions to active vision*, Arch. Rational Mech. Anal., 134 (1996), pp. 275–301.
- [7] K. Mikula, D. Ševčovič, *Evolution of plane curves driven by a nonlinear function of curvature and anisotropy*, SIAM J. Appl. Math., 61 (2001), pp. 1473–1501.
- [8] K. Mikula, D. Ševčovič, *A direct method for solving an anisotropic mean curvature flow of planar curve with an external force*, Mathematical Methods in Applied Sciences, 27 (2004) pp. 1545-1565.
- [9] J. Urbán, *Evolúcia rovinných kriviek v spracovaní obrazu*, Slovenská Technická Univerzita v Bratislave, 2009.
- [10] J. Žára, B. Beneš, J. Sochor, P. Felkel, *Moderní počítačová grafika (druhé, přepracované vydání, kompletní průvodce metodami 2D a 3D grafiky)*, Computer Press, Brno , 2004, ISBN 80-251-0454-0.