

## Když rozkvetou fraktály... (4)

Pokud vás v předcházejících číslech Chipu zaujalo povídání o fraktální geometrii, nenechte si ujít jeho poslední část. Je věnována aplikaci této disciplíny ve velice perspektivním oboru umělé inteligence, v počítačovém vidění.

Jak již z názvu plyne, půjde o rozeznávání obrazců pomocí počítačů. Historie tohoto odvětví je stará přibližně jako éra PC. Byly vypracovány mnohé metody, jejichž pomocí se člověk snaží napodobit to, co jeho zrak a mozek samočinně provádějí po celou dobu života. Snímat obrazy, analyzovat je, rozdělit je na objekty, provést jejich identifikaci co do pohybu a druhu.

Vzhledem k tomu, že člověk je tvor vynalézavý a hravý, není přitom při možnostech dnešní techniky omezen jen na viditelný obor spektra, ale může pomocí počítačového vidění teoreticky rozeznávat objekty i v jiných spektrálních oblastech, například v infračervené.

Počítačové vidění lze rozdělit zhruba do těchto následujících kroků:

- + Získání digitálního obrazu.
- + Úprava obrazu.
- + Rozložení obrazu na objekty.
- + Popis jednotlivých objektů.
- + Klasifikace jednotlivých objektů.

**Získání digitálního obrazu** je proces, při němž se zařízení typu scanner či videokamera používají k vytvoření daného obrazu a k jeho převedení do digitální podoby. Tento proces velmi významně ovlivňuje všechny následující, neboť na kvalitě obrazu záleží, jak budou další kroky úspěšné. Například pokud získáme obraz, v němž vinou horšího snímacího zařízení nebudou zachyceny jisté detaily, pak samozřejmě také nebudou nalezeny a zpracovány v dalších krocích. To může mít nepříjemný důsledek – zejména v případech, kdy se jedná například o vyhodnocování špionážních snímků apod.

**Úpravou obrazu** rozumíme v podstatě použití různých filtrů a opravných mechanismů k odstranění poruch obrazu (nejrůznějších šumů vniklých do obrazu, ať už před vstupem do kamery, či během zpracování). Během tohoto procesu se nejen odstraňuje šum, ale také zlepšuje kvalita obrazu, například vyostřováním hran, potlačením, či zvýrazněním některých vlastností obrazu pomocí filtrace, apod.

Jakmile je obraz upraven, je možné provést jeho **rozložení na jednotlivé objekty**. Za tímto účelem bylo vyvinuto několik metod, jako je *segmentace prahováním* (za využití určitých vlastností obrazu se zvýrazní některé objekty), *segmentace narůstáním oblastí* (zde se obraz rozčleňuje na homogenní celky; kritérium homogenity může být založeno např. na jasových vlastnostech) a další.

Takto připravené objekty je třeba **popsat** nějakým vhodným způsobem, který by umožnil jejich jednoznačnou klasifikaci. To lze udělat např. *binárním popisem*, který se dá bez problémů aplikovat na černobílý obrazce tak, že se vytvoří vektor či matice s prvky 0, nebo 1 podle toho, zda byl daný pixel bílý, či černý – výsledkem jsou pochopitelně velké objemy dat, což není žádoucí. Další možností je *hraniční popis*, při němž se hranice objektu "rozsekají" na stejné úseky a jejich orientace se opět zapíše jako vektor čísel, ze kterého lze takovýto objekt opět snadno rekonstruovat.

Oba přístupy mají své nedostatky. Binární produkuje často neúnosné objemy dat a hraniční není jednoznačný (ztrácí se informace o struktuře objektu). Jako slibný směr (samozřejmě mimo jiné existující metody) se zde jeví právě použití fraktální geometrie – a to nejen pro popis, ale i pro následnou **klasifikaci**. Tento přístup zcela vylučuje velké objemy dat i nejednoznačnosti vyplývající z hraničního popisu.

Celý princip je založen na faktu, že každý objekt lze popsat pomocí malého množství čísel, která jej jednoznačně určují. "Fraktálový" přístup za tím účelem zjistí koeficienty tzv. afinních transformací, které daný objekt generují, a tyto koeficienty pak použije při klasifikaci tohoto objektu např. pomocí neuronové sítě.

Metodu lze demonstrovat na ukázkovém příkladu, který se skládal ze tří experimentů. První byl zaměřen na dobu učení, druhý zjišťoval, zda neuronová síť dokáže pomocí fraktálního popisu rozeznávat příslušné objekty, a ve třetím se řešil tzv. inverzní fraktální problém (IFP). Třetí experiment v podstatě demonstruje, že např. pomocí evolučních algoritmů je možné nalézt koeficienty afinních transformací, které generují příslušný fraktál.

### Experiment 1 – učení

Zde byly použity dvě třívrstvé sítě s topologiemi vhodnými pro řešení problém a porovnávaly

se dva přístupy: binární a fraktální. Cílem bylo naučit síť na co nejmenší chybu. Jak je zřejmé z obrázku 1, fraktální přístup byl jednoznačně lepší. Neuronová síť zvládla učení ve fraktálním popisu za desetinu doby, přičemž se učila na celém objektu – Sierpinského trojúhelník (viz obr. 3). Učení pomocí binárního popisu naprosto neuspělo, přestože bylo "lehčí", neboť místo celého objektu popisovalo jen jeho vrcholek, tj. asi 1/4 celého objektu.

## Experiment 2 – rozeznávání

Ve druhém experimentu se zkoušelo rozeznávání. Byla vytvořena matice popisující fraktál bludiště, který byl mutován tak, aby se nakonec přeměnil na Sierpinského trojúhelník (obr. 2). K mutaci byly použity faktory rotací a zmenšení v příslušných afinních transformacích. Zároveň s touto maticí se generovala trénovací množina – co mutant, to dvojice vektorů v trénovací množině; na ní pak byla síť učena.

Dvojice vektorů v trénovací množině byly zvoleny tak, že vstupní vektory do sítě byly vektory afinních transformací daného objektu-mutanta a výstupní vektor byl kombinací 0 a 1. Šlo tedy o klasifikaci do tří tříd (obr. 3).

Po učení byly síti předkládány postupně jednotliví mutanti a zaznamenávány odpovědi sítě – vidíte je na obr. 4. Třem výstupním neuronům zde odpovídají tři sloupcové grafy. Hodnota 1 znamená, že příslušný vstup patří do dané třídy (levý – "větev", prostřední – bludiště, pravý – trojúhelník; srv. obr. 3), hodnota 0, že nepatří.

Z obrázku 4 je jasně vidět, že se síť naučila klasifikovat. "Zmatená" byla jenom mezi dvěma černými hranicemi, kdy nebyla schopna říci, kam daný vstup patří (bludiště, či trojúhelník?). Tato neurčitost však byla téměř minimální, a proto lze experiment považovat za úspěšný. Vždyť to, že síť nebyla schopna rozeznat čtyři vstupní objekty, není nijak řídký jev ani v lidském vidění – naše neuronové síť (mozky) také mnohdy nerozeznají předmět kvůli jeho vzdálenosti, natočení či nějakému jinému nedostatku vizuálních informací.

## Experiment 3 – inverzní fraktální problém

I když předchozí experiment dopadl dobře, pořád zůstává nezodpovězena otázka, jak získat koeficienty afinních transformací od reálných objektů. V tomto experimentu proto byla pro identifikaci těchto koeficientů použita diferenciální evoluce, pro niž byla definována účelová funkce. Jejím minimalizací pak vedla k nalezení afinních transformací, které generují originální fraktál.

Jako originální fraktál, jehož afinní transformace měly být identifikovány, byl použit tzv. pavouk a Mandelbrotův vír. Ty byly převedeny do matic, v nichž 1 znamenala černý bod a 0 bílý. Diferenciální evoluce pak evolučním procesem "šlechtila" generace nevhodnějších fraktálů; po 2000 generacích byl proces šlechtění ukončen a jako identifikovaný fraktál byl vzat nejlepší z poslední generace. Výsledky vidíte na obrázcích 5 a 6.

Každý fraktál v každé generaci byl reprezentován maticí nul a jedniček a porovnáván s maticí originálního fraktálu. Jako tzv. Hammingova (binární) vzdálenost, která byla minimalizována, se brala suma všech jedniček, které se v maticích nepřekrývaly (tj. černé "čtverečky", které se nepřekrývaly) – právě těmito body se fraktály od sebe lišily. Suma rovnající se nule pak znamená, že oba fraktály jsou na dané úrovni rozlišení plně totožné.

Jak je z uvedených obrázků vidět, shoda mezi originály a rekonstrukcí byla velmi dobrá. Hodnoty, které v algoritmu TEA generovaly identifikovaný fraktál, se od originálních hodnot lišily jen v setinách. Vlastní evoluce si vyžádala 2 1/2 hodiny v prostředí *Mathematica*® na počítači PC/Pentium MMX s taktem 230 MHz. V jazycích jako např. C++ by byla jistě mnohem rychlejší (podle posledního experimentu 5 minut pro 2000 generací, v každé generaci bylo 40 jedinců).

Výsledek tohoto experimentu je velmi dobrý a ukazuje, že je možné použít evoluční algoritmy na identifikaci fraktálů nejen umělých, ale i na fraktály reálného světa, jakým je např. naše známá kapradina. Vzhledem k tomu, že fraktály nejsou jen grafické objekty, ale lze na ně pohlížet také jako na "výslednici" chování dynamických systémů, nabyvá jejich možná identifikace na významu ještě více.

## Závěr

I když zde uvedené informace o fraktální geometrii a jejím využití byly jen velmi strohé, lze z nich snad "vycítit", že fraktální geometrie není jen módním trendem, jak to tvrdí různí lidé, ale je jedním z nových a životaschopných směrů, které se v současné vědě začínají objevovat. Popustíme-li uzdu fantazii, snadno přijdeme na další aplikace těchto matematických "monster". Uvažujme například o rozeznávání a syntéze zvuku. Lze-li pomocí fraktální geometrie snadno

popsat datově náročné obrazy, proč by to nešlo i se zvukem? Fraktální popis se totiž hodí nejen pro grafické objekty, ale i pro časové průběhy (fraktální interpolace – [6]). V případě využití takové metody nezískáme jen vhodný popis daného zvuku pro rozeznání či diagnostiku, ale také ekvivalent daného zvuku o vysoké kompresi. Problém syntézy je v podstatě už jen opačný postup – z daného fraktálního popisu se vygeneruje příslušný zvukový fraktál.

Lze tedy očekávat, že se s fraktály budeme setkávat stále častěji v mnoha oborech – a možná i s tím, že o jejich momentálním využití v nějakém postupu nebudeme mít ani ponětí.

*Ivan Zelinka (zelinka@zlin.vutbr.cz)*

#### **Použitá a doporučená literatura**

**[1]** Peitgen H. O., Jurgens H., Saupe D.: Chaos and Fractals, New Frontiers of Science, Springer-Verlag 1992, ISBN 3-540-97903-4.

**[2]** Barnsley M. F., Fractals Everywhere: Academic Press Professional 1993, ISBN 0-12-079061-0.

**[4]** Bunde A., Shlomo H.: Fractals and Disordered Systems, Springer, Berlin, 1996, ISBN 3-540-56219-2.

**[5]** Hastings H. M., Sugihara G.: Fractals a User's Guide For The Natural Sciences, Oxford University Press, 1993, ISBN 0-19-854597-5.

**[6]** Zelinka I.: Aplikovaná informatika, FT VUT Zlín (v tisku).

**[7]** Zelinka I.: Umělá inteligence I, VUT Brno, 1998, ISBN 80-214-1163-5.

**[8]** Coveney P., Hihgfield R.: Šíp času, Oldag Publishers, 1995, ISBN 80-85954-08-5.

**[9]** Nicolis G., Prigorine I.: Self-Organization in Nonequilibrium Systems, John Wiley & Sons, 1977, ISBN 0-471-02401-5.

**[10]** Hilborn R. C.: Chaos and Nonlinear Dynamics, Oxford University Press, 1994, ISBN 0-19-508816-8.

**[11]** Zelinka I. – editor: Nostradamus Prediction