

COMPRESSION METHODS BASED ON CONTEXT MODELLING

Filip Kozák

Master Degree Programme (2), FIT BUT

E-mail: xkozak12@stud.fit.vutbr.cz

Supervised by: David Bařina

E-mail: ibarina@fit.vutbr.cz

Abstract: This paper presents compression method based on the context modeling, which is focused on the image data processing. In this case, context is formed by previously processed pixels. This work deals with the adaptation of compression based on the PPM method in conjunction with the arithmetic encoder on image data. Compression method and compression results obtained with various lengths of context on different images will be introduced in this paper. Achieved results are close to PNG graphics format.

Keywords: PPM, arithmetic coder, context modeling, image compression

1 ÚVOD

V súčasnosti pozorujeme prudký nárast objemu dát, hlavne multimediálnych. V tomto kontexte sa prirodzene objavuje snaha zmeniť ich veľkosť, na čo sa používajú mnohé, stratové či nestratové, kompresné metódy. Moja práca sa zameriava na bezstratovú kompresiu 2D obrazových dát. Využívam v nej kontextovú kompresnú metódu vychádzajúcu z rodiny metód PPMx. Pojem kontextová kompresia znamená, že sa používa určitý kontext, napr. niekoľko posledne spracovaných pixelov, na predikciu ďalšieho pixelu. V nasledujúcich kapitolách budú stručne popísané použité kompresné metódy a doteraz dosiahnuté výsledky práce, porovnané s formátom PNG.

2 KONTEXTOVÁ KOMPRESIA OBRAZU

Najznámejšími predstaviteľmi kontextovej kompresie obrazu sú formáty JPEG 2000 a PNG. JPEG 2000 využíva algoritmus EBCOT (používa vlnkovú transformáciu a rozdelenie do pásem a nezávislých blokov) v spojení s aritmetickým kóderom. PNG vyžíva predikciu pixelu z okolných pixelov nasledovanú algoritmom Deflate (používaný v ZIP kompresii).


V mojej práci sa kompresná metóda skladá z dvoch základných častí: adaptívneho aritmetického kódera a postupu vychádzajúceho z rodiny metód PPM. V práci sa zaobérám adaptáciou kompresnej metódy PPMx na obraz. Základné princípy týchto metód sú bližšie predstavené v nasledujúcej kapitole.

3 POUŽITÉ ALGORITMY

Aritmetické kódovanie: Väčšina kompresných metód je založená na priradovaní kódov jednotlivým symbolom alebo frázam zo vstupného súboru. Aritmetické kódovanie však prideľuje jeden dlhý kód celému súboru. Dá sa povedať, že celý vstupný súbor bude vyjadrený číslom z intervalu $\langle 0, 1 \rangle$.

Metóda začína s intervalom $\langle 0, 1 \rangle$, ktorý sa postupne zužuje počas čítania vstupného súboru. Špecifikácia užšieho intervalu vyžaduje ďalšie bity, takže dĺžka čísla, ktoré algoritmus konštruuje, priebežne rastie [1]. Výsledkom je dlhé desatinné číslo, ktoré sa nachádza v konečnom zúženom intervale.

Princíp metódy ilustruje obrázok 1, ktorý zobrazuje zužovanie intervalu pri kódovaní reťazca ABCA. Aktuálny interval sa vždy delí v pomere výskytu jednotlivých znakov a ďalej sa pracuje s tým podintervalom, ktorý prislúcha aktuálne kódovanému znaku. Tento jednoduchý príklad predpokladá, že pravdepodobnosti výskytu jednotlivých znakov sú známe už pred kódovaním.



Obrázok 1: Zužovanie intervalu pri aritmetickom kódovaní.


Algoritmus adaptívneho aritmetického kódovania v tejto práci bol implementovaný podľa publikácií *Arithmetic coding for data compression* z roku 1987 [2] a *Arithmetic Coding revealed* z roku 2007 [3].

Metóda PPM – Prediction by Partial Matching je bezstratová kompresná metóda používajúca kontext rádu N spolu s adaptívnym pravdepodobnostným modelom. Metódu vynášli *John Cleary* a *Ian Witten* v roku 1984 [4]. Pod pojmom kontext symbolu rozumieme N symbolov, ktoré predchádzajú daný symbol. N nazývame rád kontextu. Pretože dekóder nepozná budúci text (symboly), musí sa kontext obmedziť len na predchádzajúce symboly.

Pravdepodobnostný model metódy PPM je tvorený dátovou štruktúrou, ktorá uchováva všetky n-tice symbolov, ktoré sa doteraz objavili spolu s frekvenciami výskytu symbolov, ktoré nasledovali po nich. V tejto štruktúre sú uložené kontexty rádu 0 až N (teda n-tice majú dĺžku 0 až N). Na reprezentáciu tejto štruktúry sa často používa stromová štruktúra *trie*. PPM kóder sa snaží nájsť symbol v čo najdlhšom kontexte, po jeho nájdení sa odošle aritmetickému kóderu frekvencia výskytu daného symbolu v príslušnom kontexte [5].

4 IMPLEMENTÁCIA A DOSIAHNUTÉ VÝSLEDKY

V mojej práci pracujem s kontextom konštantnej dĺžky, vďaka čomu nie je potrebné použiť štruktúru trie. Za kontext je považovaných N okolitých (už skôr spracovaných) pixelov – vid' obrázok 2a. Kontext je teda možné ľahko určiť z niekoľkých predchádzajúcich pixelov. Na rozdiel od metódy PPM nepoužívam skracovanie kontextu. K aktuálne spracovávanému pixelu sa určí kontext, na základe čoho sa určí frekvencia výskytu symbolu v tomto kontexte. Táto frekvencia sa následne zakóduje aritmetickým kóderom a aktualizuje sa pamäťový model.



Obrázok 2: Kontext v obrázku tvorený už spracovanými pixelmi.

Program som testoval na niekoľkých obrázkoch¹ prevedených do stupňov šedi. Dosiahnuté výsledky kompresie (v KiB) sú v tabuľke 1. Táto tabuľka obsahuje aj porovnanie s formátom BMP (8 bitovým) a PNG (s najväčším stupňom kompresie). V tabuľke sú veľkosti skomprimovaných súborov pre rôzne dĺžky kontextu ($N = 0..4$) – ako kontext boli použité pixely A–D (vid' obrázok 2b).

V kontexte som zatial' neuvažoval všetkých 256 hodnôt (8 bitov), ktoré môžu nadobúdať predchádzajúce pixely, ale som ich navzorkoval na 16 hodnôt (4 bity). Touto redukciou sa výrazne zníži pamäťová

¹prevzaté z korpusu: <http://sipi.usc.edu/database/database.php?volume=misc>

náročnosť pravdepodobnostného modelu, avšak sa môžu čiastočne zhoršiť výsledky kompresie. Pri 256 symboloch a dĺžke kontextu 4 symboly by bola veľkosť pamäťového modelu rádovo v gigabajtoch.

	N = 0	N = 1	N = 2	N = 3	N = 4	PNG	BMP
lena	238,4	170,5	156,3	156,7	156,0	147,5	257,1
baboon	235,7	202,5	200,7	210,0	219,0	199,3	257,1
moon	53,8	42,5	42,7	43,8	45,7	41,3	65,1
ruler	16,4	12,8	7,5	2,8	2,8	2,9	257,1

Tabuľka 1: Výsledky kompresie pri rôznych dĺžkach kontextu.

V kontexte dĺžky 0 ($N = 0$) neboli brané do úvahy žiadne predchádzajúce pixely (jedná sa vlastne len o kompresiu adaptívnym aritmetickým kóderom).

Do kontextu boli postupne pridávané pixely A – D (vid' obrázok 2b). Pri kontextoch kratších ako 4 som skúšal rôzne kombinácie okolitých pixelov, avšak výsledná veľkosť súboru sa líšila len v jednotkách percent. Výsledky jedného z týchto experimentov sú v tabuľke 2, ktorá zobrazuje dosiahnutú kompresiu pre rôzne pixely tvoriace kontext dĺžky 1 ($N = 1$).

	A	B	C	D
lena	170,5	162,3	175,5	171,3
baboon	202,5	211,8	215,4	215,4

Tabuľka 2: Výsledky kompresie pri rôznych pixeloch tvoriacich kontext.

Kedže pamäťová náročnosť so vzrastajúcou dĺžkou kontextu exponenciálne rastie, je vhodné implementovať efektívnejší pravdepodobnostný model (týmto by sa tiež eliminovala potreba vzorkovania 256 hodnôt na 16).

5 ZÁVER

Výsledkami práce som sa priblížil formátu PNG, ktorý však neboli prekonaný. Dosiahnutú kompresiu je možné nadálej zlepšovať implementáciou lepšieho pamäťového modelu, ktorý by umožnil spracovavať dlhší kontext alebo odlišným spôsobom určovania kontextu. Zdokonalenie kompresie môže byť objektom ďalšieho štúdia.

POĎAKOVANIE

Tento príspevok vznikol za podpory grantu FIT-S-11-2 a výskumného zámeru MSM 0021630528.

LITERATÚRA

- [1] Salomon D.: Data compression: The complete reference, Springer, 2007, 4. vydanie, ISBN 1-84628-602-6
- [2] Witten I., Neal R., Cleary J.: Arithmetic coding for data compression, Communications of the ACM, jún 1987, s. 520 – 540, ISSN 0001-0782
- [3] Bodden E., Clasen M., Kneis J.: Arithmetic Coding revealed – A guided tour from theory to praxis, SABLE-TR-2007-5, Montréal, Québec, Canada, 2007
- [4] Cleary G., Witten I.: Data Compression Using Adaptive Coding and Partial String Matching, IEEE Transactions on Communications, apríl 1984, s. 396 – 402, ISSN 0090-6778
- [5] Cleary J., Teahan W., Witten I.: Unbounded length contexts for PPM, In: Data Compression Conference, DCC '95, Snowbird, Utah, marec 1995, s. 52 – 61, ISBN 0-8186-7012-6