

# Párhuzamos Gauss - Seidel algoritmus ritka power system mátrixokhoz (elemzés)

Arany Kamill

2007.03.06.

Gauss - Seidel algoritmus:

$A \cdot x = b$  lineáris egyenletrendszer megoldására használható iterációs módszer. A  $n \times n$ -es ritka mátrix,  $x$  és  $b$  pedig  $n$  hosszú vektorok.  $x = Cx + c$  fixpont egyenlet alakra formáljuk és kiindulva egy tetszőleges  $x_0$  kezdővektorból, képezzük az  $x_{k+1} = Cx_k + c$  közelítő megoldások sorozatát. Ha  $x_k$  sorozat konvergens és tart az  $x^*$ -hoz akkor az eredeti egyenletnek is megoldása lesz. További információk találhatóak <http://numanal.inf.elte.hu/soveg/> oldalon az oktatási anyagok között letölthető jegyzetben.

Megváltoztatni egy ritka mátrixban a rendezettséget az egy permutációs mátrix segítségével lehetséges.  $(PAP^T)(Px) = (Pb)$

Lehetséges párhuzamosítások:

Amíg a Gauss-Seidel algoritmus sűrű mátrixokra szekvenciális, lehetséges azonosítani ritka mátrix partíciókat amikben nincs közös adat, tehát a számítás működhet párhuzamosan, és közben a szigorú precedencia szabályait is megtartjuk a Gauss-Seidel módszernek. Tehát egy egész ritka mátrix partíció számolható párhuzamosan mindenfajta kommunikáció nélkül. Blokk diagonális felbontást használunk a párhuzamosításhoz. Az utolsó diagonális blokk reprezentálja az összekapcsolódási struktúrát az egyenleten belül, ami párosítja a partíciókat a mátrix blokk diagonális részébe. Az egyenleteket gráffal reprezentáljuk amit színezni tudunk. A különálló színek sorokat reprezentálnak ahol  $x^{k+1}$  párhuzamosan számolható, mert egy színben belül nincs két csúcs között él. Definiáljuk a lineáris egyenletrendszer egy particionálását, ahol a  $P$  permutációs mátrix rendezi a mátrixunkat blokk diagonális formába.

$$PAP^T := \begin{bmatrix} A_{1,1} & 0 & \dots & A_{1,m} \\ 0 & \dots & \dots & \dots \\ \dots & \dots & A_{m-1,m-1} & A_{m-1,m} \\ A_{m,1} & \dots & A_{m,m-1} & A_{m,m} \end{bmatrix}$$

Ha a blokk diagonál mátrix partíciók  $A_{i,i}, A_{m,i}$ , és  $A_{i,m}$  ( $1 \leq i \leq m-1$ ) ugyan arra a processzorra kerülnek, akkor nincs kommunikáció amíg  $x_m^{k+1}$  kiértékelődik. Kell egy módszer amivel ilyen blokk diagonális alak elérhető. Erre a csúcs-szakító (node-tearing) algoritmust használjuk aminek van egy felhasználó által megadható bemeneti paramétere,  $max_{DB}$ , a diagonális blokkok

maximális mérete. E paraméter változtatása nagyban befolyásolja a párhuzamos algoritmusunk teljesítményét.

A párhuzamos algoritmus a következő részekből áll:

1.  $x^{(k+1)}$  kiszámítása a diagonális blokkokban
2.  $\hat{b}$  kiszámítása a (mátrix  $\times$  vektor) párhuzamos előállításai által
3.  $\hat{x}^{(k+1)}$  kiszámítása az utolsó diagonális blokkban.
4. konvergencia ellenőrzése

Tapasztalati eredmények:

A párhuzamos Gauss-Seidel algoritmus teljesítménye két összetevőtől függ nagyon. Az egyik a mátrix rendezés teljesítménye az előfeldolgozási fázisban, a másik pedig a párhuzamos Gauss-Seidel implementálásátálása. Először mindenféle sebesség méréseket vezettek 3 nagy kiterjedésű mátrixon. Ezeket a mátrixokat egy szekvenciális program segítségével rendezték, és előállították az adatstruktúrát a párhuzamos algoritmus számára. Ezen előfeldolgozás során többféle  $max_{DB}$  (a blokk diagonális mátrixá alakító algoritmus bemenő paramétere) értéket használtak. A tapasztalati eredményeket egy NPAC CM-5 nevezetű gép segítségével szerezték (1-32 processzort használva). Az 5. ábra mutatja ezt a relatív sebességet aszerint, hogy 2,4,8,16 vagy 32 processzort használtak. Látható, hogy logaritmikus fv-hez hasonló az egyes bemenő mátrixokhoz a gyorsulás függvénye. Az EPRI-6K nevezetű mátrixnál a legjobb a teljesítménye az algoritmusnak, a másik 2 mátrixra körülbelül azonos. Ez annak a következménye, hogy a teljes számítási kapacitás 5% -a az utolsó diagonális blokk kiszámítása, mivel itt sok kommunikáció történik a többi folyamattal.

A relatív sebesség részletes vizsgálata található a 6. ábrán az EPRI-6K adatra. Azt mutatja, hogyan változik a gyorsaság a partíciók számának függvényében a blokk diagonális formára hozó algoritmusban. Jól mutatja a terhelesi egyensúlyhiányt ez a grafikon. A 4 bemenő adatra 16 processzor használatáig körülbelül azonosak a sebességek, azonban 32 processzornal szétválnak és látható, hogy több partíció esetén rosszabb a sebesség. Valamint vizsgáljuk meg a sebességet az algoritmusunk 4 különböző szakaszában. A 7. ábrán lévő 4 diagram ezeket az eseteket mutatja be, annak függvényében, hogy mekkora volt a  $max_{DB}$  érték (4 különböző értékre vizsgálták: 128, 192, 256, 320). Logikus elvárás, hogy a processzorszám növelésével a lehető legjobb időt érjük el, azaz a függvények egy vonal mentén folyamatosan csökkenjenek. Ez a feltevés a mérési eredményeket nézve nagyrészt igaz, kivéve a utolsó blokk számításánál, ahol nagy mértékben megugrik a számítási idő a processzorszám duplázása közben (ez jól látszik 8 processzor után). Ennek egy oka, hogy egyes mátrix rendezésekre nem tudja elosztani a munkát egyenletesen nagy számú processzorok esetén. Ez főleg akkor fordul elő ha a  $max_{DB}$  értéket túl nagyra választjuk. Kisebb  $max_{DB}$  értéknél még 60 vagy több processzorra is jobb sebesség érhető el.

Ismét elmondanám, hogy minden elérhető párhuzamosítás ebben a munkában a mátrixrendezés eredménye és felismerni az összefüggést a mátrix struktúráján belüli kapcsolódási mintában. Azon mátrixok amikben a tesztet végezték elég rendhagyóak és speciálisak, a legkritikább mátrixok közé tartoznak ilyen szempontból. A csúcok 84,4% -ának 3 vagy kevesebb éle van az EPRI-6K adatban. Következésképpen ezek a mátrixok jelentős kihívást adnak arra, hogy

előállítsunk hatékony párhuzamos algoritmusokat ritka mátrixokra. A 8. ábrán látható egy tipikus rendezése az EPRI-6K -nak ahol a  $max_{DB}$  egyenlő 256 csúccsal. Ez a mátrix reprezentálja a hálózati gráf szomszédsági struktúráját és világosan mutatja a ritkaságot. A nem 0 elemek pontokkal vannak feltüntetve.

Következtetés

Az cikkben bemutatott párhuzamos Gauss-Seidel algoritmus az említett ritka és rendhagyó mátrixok esetén jó relatív gyorsulást mutat. A blokk diagonális mátrix felbontás megkönnyítette az implementációt és a probléma dekomponálását könnyebben feldolgozható részekre. A már említett node-tearing algoritmus segítségével megoldható a mátrix rendezése ilyen mátrixok esetén, és csökkenthető az egymástól függő egyenlet párok száma, amiből az következik, hogy a gráf-színező algoritmusnak általában elég 2 vagy 3 szín az utolsó blokk színezésénél. A mátrixelemek közötti aktuális kapcsolatok meghatározása után lehetett bármiféle párhuzamosítást végezni (minél kevesebb egymás közötti kommunikációval járjon a processzorok munkája, és akkor nagy gyorsulás érhető el), ez derult ki a cikkből az elemzés során. Tehát lehet érezni, hogy a lehetséges párhuzamosítások korlátozottak. Megmutatták azt is, hogy relatív hatékonyság csökkenés érhető el, persze a mátrixtól függően, ha 8 processzornál többet használunk futás közben.

Mivel elég speciálisnak kell lennie a bemenetnek ahhoz, hogy az algoritmus utolsó részében is hatékony gyorsulást tudjunk elérni a processzorszám növelésével, a következő elemzés az algoritmus első részének vizsgálatára szorítkozik. A teljes algoritmus kódja megtalálható a mellékelt cikkben. Nézzük az első részét,  $x^{(k+1)}$  kiszámítása a diagonális blokkokban:

```
for minden i-edik sorra ezen a processzoron
  x'_i <- x_i
  x_i <- b_i
  for j eleme [1,n] ahol a_ij nem egyenlő 0
    x_i <- x_i - (a_ij * x_j)
  endfor
  x_i <- x_i / aii
endfor
```

Ahhoz, hogy a fenti problémát megoldjuk szükségünk van egy alkalmas párhuzamos környezetre amiben lehetőség van több processzor között elosztani a munkát, és így a futási időt nagymértékben csökkenteni tudjuk. Ilyen lehetőséget nyújtanak a PVM vagy MPI programok, amiket egy daemon segítségével egyszerre több processzoron vagyunk képesek futtatni. Azonban egy sokkal érdekesebb és napjainkban egyre nagyobb teret kapó rendszert választottam a szimulációhoz, ami a GRID. A többszintű párhuzamosság érhető el a GRID rendszerekben. Meghatározhatom, hogy mely erőforrásokat szeretném igénybe venni, persze csak azok közül amelyekre jogosultságom van.

A szimulációm a HUNGRID -ben végeztem, amibe az ELTE-s portal segítségével jelentkeztem be: <http://pgrade.inf.elte.hu> címen érhető el. Workflow szerkezetű programokat képes futtatni a GRID-ben a portal. Ez a egy irányított körmentes gráf amiben az egyes részprogramok (job) elindulása függ az öt megelőzőektől, ha valami adatot vár amire szüksége van. Több ilyen gráfra végeztem futási eredmény vizsgálatot. Az eltérések ezek között a számított

mátrixok mérete, és ennek megfelelően a gráf csúcsainak száma. Ezen méreteket a már fentebb említett  $max_{DB}$  érték határozza meg. A GRID-ben egy ilyen workflow elindítása után csak percekkel később kezdenek el futni a csúcsokban definiált programok, ennek oka a sok előzetes kommunikációban, a terheltségben és a jogosultságok vizsgálatában keresendő. Azonban ha egy program több óráig is fut, ez a pár perc a futási időben elenyésző. Az első mérési eredmény pontosan erre vonatkozik. Ha a  $max_{DB}$  túl nagy a diagonális blokkok kicsik lesznek. Ezek a kis részmatrixokon végzett számítások hamar befejeződnek. Itt a programok elindulásához szükséges idő nagyobb a futási időnél. Ezután azt vizsgáltam, hogy a mátrixok méretének növekedése hogyan befolyásolja a futási időt.

Az egyszerű elemzés érdekében  $n \times n$ -es mátrixokat vizsgáltam. A futási idők arányai érdekesek számunkra, ezért tényleges mértékegységet nem adok sehol, csak nagyságrendekkel próbálom érzékeltetni az eltelt időt. A futási idő nem változott nagy mértékben ha  $n$  értéke 1000 alatt volt. Az előkészületek a futáshoz nagyságrendileg megegyeztek, mivel az adatokat elküldeni a processzorhoz körülbelül ugyan annyi időbe telt tetszőleges  $n$  esetén, valamint az eredmény visszaérkezése is hasonló időt vett igénybe. Ez a teljes futási idő 5, ha  $n \leq 1000$ , egy processzoron. De az  $n$  növelésével a futási idő nagyban nőtt.  $n = 1700$ -ra már 7,  $n = 2400$ -ra 17,  $n = 3100$ -ra körülbelül 50-ra változott a futási idő. Fontos kihangsúlyozni, hogy ezek a futási idők egy processzorra vonatkoznak. Jól látható ebből, hogy a futási idő  $n$ -hez (amit lineárisan növelek) nézve sokkal gyorsabban nő (mélyreható számításokat nem végeztem, de talán mondhatom azt, hogy exponenciálisan nő). Azonban ha egymás mellett több ilyen számítást is elindítok, ezek egymással párhuzamosan tudnak futni a GRID-ben. Tehát a futási idő azonos lesz ha 2, 3 vagy  $m$  db ilyen számítást indítok el párhuzamosan, mert nem várnak egymástól adatot. Persze függ a gridben lévő erőforrások terheltségétől, de pl. ha 10 db program fut amely mindegyike  $n = 2400$  akkor a futási idő 17 lesz. Itt tudunk elérni nagyfokú párhuzamosítást.

Ha van kezdetben egy mátrix ahol  $n = 10000$ , ezt blokkdiagonális formára hozva elérjük azt, hogy sok kis részmatrixon kell számításokat végezni, amiket ráadásul lehet párhuzamosan is futtatni. Pl. ha 4 darab diagonális blokkunk van akkor a mellékelt ábrán lévő workflow fut, amiben a négy egymás mellett lévő csúcs egyszerre képes futni. Tehát a következtetés az, hogy ha megvan a blokkdiagonális felbontás, párhuzamosítással elég nagy gyorsítása érhető el az algoritmusnak. Az egész elemzés és szimuláció arra irányult, hogy bebizonyítsam, a GRID teljesen alkalmas az adott probléma megoldására, valamint a SZTAKI által fejlesztett portál segítségével egyszerűen tudjuk futtatni párhuzamosan a programjainkat, illetve a fent említett problémára adott programot.