

ترکیب الگوریتم ژنتیک با الگوریتم تپه نوردی در ماشین با ساختار موازی برای بهینه سازی پرس و جوهای بزرگ در گراف پرسش

سعید پارسا، حبیب ایزدخواه و امیر حسین زاده

آدرس محل کار : دانشگاه علم و صنعت ایران، دانشگاه آزاد واحد عجب شیر و دانشگاه آزاد واحد خاмене

E-mail: parsa@iust.ac.ir, habib_eizadkhah@yahoo.com, amirhosseinzade@yahoo.com

چکیده - بهینه سازی پرس و جو یک فرآیند گران و پرهزینه می باشد و تعداد جایگشت های مختلف برای یک پرس و جو بصورت نمائی با تعداد روابط سهیم در پرس و جو رشد می کنند. تکنیکهای فعلی بهینه سازی پرس و جو برای پشتیبانی بعضی از کاربرد های ناشی از پایگاه داده که دارای پیوندهای مختلفی از انواع پرس و جوها می باشد، نامناسب هستند از طرفی رمز موفقیت یک مدیر پایگاه داده (DBMS) کارا بودن مدل پرس و جوی آن می باشد. در این مقاله ما پرس و جوهای را بررسی می کنیم که دارای تعداد روابط زیادی بوده و همچنین گراف آنها دور داشته باشند. که این چنین پرس و جوهای زمان زیادی را برای پاسخگویی به پرس و جو نیاز دارند. ما از دو روش برای بهینه سازی این چنین پرس و جوها استفاده می کنیم. ابتدا، بر اساس الگوریتمی گرافها را به چندین درخت تجزیه نموده و سپس درختها را روی کامپیوترها توزیع و با استفاده از ترکیب الگوریتم ژنتیک با الگوریتم تپه نوردی به بهینه سازی آنها پرداختیم و در روش دوم بدون تجزیه گراف به درخت آن را روی کامپیوترها توزیع کرده و به بهینه سازی آن با استفاده از ترکیب الگوریتمهای ذکر شده پرداختیم. پس از ده بار اجرای الگوریتم و از روی نتایج بدست آمده مشخص شد که در روش اول بیشتر از روش دوم جواب بهینه به دست می آید.

کلید واژه - پایگاه داده، بهینه سازی پرس و جو، الگوریتم ژنتیک، گراف پرسش، ماشین موازی

۱- مقدمه
می برد تا در نهایت جواب برای q را بدست آورد. هزینه یک استراتژی مجموع هزینه های پردازش هر عملگر می باشد. در میان این عملگرها مشکل ترین آنها برای پردازش و بهینه سازی، عملگر پیوند (که با علامت \bowtie یا JOIN نشان داده می شود) می باشد. این عملگر دو رابطه را به عنوان ورودی دریافت می کند سپس با ترکیب تاپل ها (tuple) و با توجه به نوع پیوند، یک رابطه جدید به عنوان خروجی تولید می کند. پیوند، یک عملگر جایجا پذیر و شرکت پذیر می باشد. لذا تعداد استراتژیها برای پاسخگویی به یک پرس و جو به صورت نمائی با تعداد پیوند ها رشد می کند [15][12][4][3][2]. به عنوان مثال اگر چه دو عبارت

$(R1 JOIN R2) JOIN R3 = R1 JOIN (R2 JOIN R3)$ معادلند و خروجی یکسانی دارند ولی هزینه زمانی آنها می تواند یکسان نباشد، زیرا کاردینالتی رابطه میانی که باید ذخیره

رمز موفقیت یک DBMS به ویژه اگر با مدل رابطه ای کار داشته باشیم، کارا بودن مدل پرس و جوی بهینه سیستم می باشد. ورودی در این سیستم، یک پرس و جو مانند q به DBMS توسط کاربر می باشد. فرض کنید S مجموعه همه استراتژیهای ممکن برای پاسخگویی به پرس و جوی q باشد هر عضو S مانند s یک هزینه $C(S)$ را دارد (از نظر CPU و I/O). هدف یک الگوریتم بهینه سازی پیدا کردن یک عضو s_0 از S می باشد به طوری که [13]:

$$C(s_0) = \min_{s \in S} C(s)$$

حال بحث را در مورد پایگاه داده های رابطه ای ادامه می دهیم. یک استراتژی برای پاسخگویی به پرس و جوی q ، دنباله ای از عملگرهای جبری برای روابط پایگاه داده به کار