Sparse Polynomial Arithmetic

Alex Brandt

ORCCA, Department of Computer Science University of Western Ontario

UWORCS 2018

April 12, 2018

▲□▶ ▲□▶ ▲□▶ ▲□▶ ■ ●の00

Introduction



- High performance algorithms for sparse multivariate polynomial arithmetic over the rational numbers and integers.
 - $\rightarrow~\mathbb{Q}$ is practical for use in polynomial system solving.
 - $\rightarrow \mathbb{Z}$ to compare against the leading high-performance implementation. $^{[1],[2],[3]}$
- With careful implementations, we outperform the same algorithms $(\mathbb{Z}[X] \text{ arithmetic})$ implemented in *Maple*.
- Implementation: data structures, algorithmic tricks, and data locality.

・ロト ・ 戸 ・ ・ ヨ ・ ・ ヨ ・ ・ つ へ ()





3 Addition



5 Division





Introduction: Polynomial Definitions

A quick refresher of polynomials and related definitions...

• Variable - a symbol representing some number.

 x, y, z, \ldots

- \bullet Monomial a product of variables, each to some exponent. $$x^5yz^3$$
- **Coefficient** a numerical multiplicative factor of a monomial. 13, $\frac{7}{9}$, 2.1463

・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・

- Term a coefficient-monomial product. $13x^5yz^3$
- Polynomial a summation of terms. $13x^3 + 7x + 9$ (univariate) $13x^5yz^3 + \frac{7}{9}x^3y^2 + 11$ (multivariate)

We are concerned with **Sparse Polynomials**. This is the natural representation of polynomials and allows for computational savings. Sparse here has a dual meaning:

- A polynomial *is sparse* if it has few non-zero coefficients. $x^9 + 1$ vs. $3x^4 + 7x^3 + 4x^2 + 1$
- A polynomial *is represented sparsely* if only its non-zero coefficients are stored.

 $1 * x^9 + 1 * x^0$ vs. $1 * x^9 + 0 * x^8 + 0 * x^7 + \ldots + 1 * x^0$

・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・

Introduction: Notations

Throughout this presentation we use the following notation:

$$a = \sum_{i=1}^{n} a_i X^{\alpha_i}$$
 $b = \sum_{i=1}^{m} b_i X^{\beta_i}$ $c = \sum_{i=1}^{k} c_i X^{\gamma_i}$

- a, b, c are polynomials with n, m, k terms, respectively.
- a_i, b_i, c_i are non-zero coefficients.
- α_i, β_i, γ_i are Exponent Vectors, representing the exponents of a multivariate monomial over a product of some variables, X.
- $lm(a) = X^{\alpha_1}$ is the *leading monomial* of a.
- $lt(a) = a_1 X^{\alpha_1}$ is the *leading term* of a.
- $\mathbb{Q}[X]$: multivariate polynomials with rational number coefficients.
- $\mathbb{Z}[X]$: multivariate polynomials with integer coefficients.

To obtain a **Canonical Representation** of a polynomial it should have its terms sorted in some way. Certain operations thus become more efficient:

• Equality testing, leading coefficient, degree, etc.

Sorting uses some total ordering of monomials.

• Increasing or decreasing order is often arbitrary, depending on the application and data structure.

We use decreasing lexicographical ordering for monomials. For a variable ordering x > y we get the following monomial ordering:

$$x^n y^n > x^{n-1} y^n > \dots > xy > x > y^n > y^{n-1} > \dots > y$$

Polynomial Representations

▲□▶ ▲□▶ ▲ 三▶ ▲ 三▶ 三三 - のへぐ

Sparse Polynomial Representation - Linked List

A simple scheme to encode a polynomial is a **Linked List**. Each node represents a single term of the polynomial and these nodes are strung together to form a list.

$$13 \quad x^2y^3 \bullet \longrightarrow 5 \quad x^2y \quad \bullet \longrightarrow 7 \quad y^3z \quad \bullet \longrightarrow \cdots$$

・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・

Advantages:

• Easy to insert or remove terms anywhere within the list Disadvantages:

- Indexing, counting the number of terms, are O(n) operations.
- Poor data locality, latent memory accesses impact performance.

Sparse Polynomial Representation - Alternating Arrays

In contrast, an **Alternating Array** provides a compact representation with good data locality.

An alternating array *alternates* between a coefficient data element and a monomial data element.

• Each term is encoded by a pair of array elements.

13
$$x^2y^3$$
 5 x^2y 7 y^3z \cdots

Some operations, like random insertion, are difficult, but memory efficiency is more important for our arithmetic algorithms.

Maple implements a similar scheme^[3] but is limited to integer coefficients.

The simplest way to represent a monomial is a list of integers: one integer for each variable.

• Inefficient use of memory as exponents rarely approach the maximum value of a 32-bit int (4294967295).

Exponent packing^{[4],[5]} uses bit-wise operations to store many exponents in a single machine word, improving memory usage and cache complexity. Consider the monomial $x^5y^2z^3$.



Monomial comparison and multiplication now reduce to a single instruction on one machine word.

Addition

(ロ)、(型)、(E)、(E)、(E)、(O)へ(C)

Sparse Addition (1/2)

The simplest method for adding two polynomials together is to iteratively add one term from one to the other while maintaining the canonical, sorted order.

$$a + b = \left(a + b_1 X^{\beta_1}\right) + b_2 X^{\beta_2} + b_3 X^{\beta_3} + \dots$$

$$a + b = \left(a + b_1 X^{\beta_1} + b_2 X^{\beta_2}\right) + b_3 X^{\beta_3} + \dots$$

$$a + b = \left(a + b_1 X^{\beta_1} + b_2 X^{\beta_2} + b_3 X^{\beta_3}\right) + \dots$$

- This process is analogous to insertion sort.
- Using alternating arrays, it is prohibitively poor performance to insert at random positions.
- We can use the fact that both a and b are initially sorted...

Solution: Model addition as one merge step of *merge sort*.

Just as in merge sort, a and b are each pre-sorted partitions to be merged into a single partition.

- Walk left-to-right through *a* and *b*, taking the larger of the two current terms.
- Append it to the end of the sum.
- If terms are equal then we combine like terms.

$$a = 13x^{2}y^{3} + 5x^{2}y + 7y^{3}z + \dots \\ \uparrow \\ b = 6x^{2}y + 12xz^{2} + 4y^{2} + \dots \\ \uparrow \\ \end{pmatrix} c = 13x^{2}y^{3} + 11x^{2}y + \\ \uparrow \\ \uparrow$$

The key idea here is that the terms in the sum are *generated in sorted order*.

Sparse Addition: Benchmarks

Addition is a very simple algorithm.

- Very little arithmetic work.
- A memory bound problem; must access memory efficiently.

We compare linked lists, without exponent packing, against alternating arrays with exponent packing.

Note: *sparsity* is quantified as the maximum difference between exponents in successive monomials.

• This difference is done by viewing an exponent vector of v variables as digits of a number in radix r:

 $r = \sqrt[v]{\text{sparsity} \times \text{number of terms}}$

Sparse Addition: Benchmarks





590

Multiplcation

◆□▶ ◆□▶ ◆三▶ ◆三▶ 三回 のへぐ

Sparse Multiplication (1/2)

The task of multiplying two polynomials is actually three in one.

- Generate the terms of the multiplication,
- Combine like-terms,
- 3 Sort the resulting terms in decreasing order.

The simplest multiplication involves distributing each term of the multiplier (a) over the multiplicand (b), combining like-terms.

$$c = a \cdot b = (a_1 x^{\alpha_1} * b) + (a_2 x^{\alpha_2} * b) + \dots$$

• Produces all $n \cdot m$ terms regardless of combining like-terms.

・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・

• Terms must be sorted after combining.

Like addition, we should try to generate terms in sorted order.

Sparse Multiplication: (2/2)

Solution: An *n*-way merge of "streams" where each stream represents a single term of *a* distributed over b.^[6]

• Since b is sorted, and we multiply by a single term of a, the resulting "stream" is also sorted.

$$a \cdot b = \begin{cases} (a_1 * b_1) X^{\alpha_1 + \beta_1} + (a_1 * b_2) X^{\alpha_1 + \beta_2} + (a_1 * b_3) X^{\alpha_1 + \beta_3} + \dots \\ (a_2 * b_1) X^{\alpha_2 + \beta_1} + (a_2 * b_2) X^{\alpha_2 + \beta_2} + (a_2 * b_3) X^{\alpha_2 + \beta_3} + \dots \\ \vdots \\ (a_n * b_1) X^{\alpha_n + \beta_1} + (a_n * b_2) X^{\alpha_n + \beta_2} + (a_n * b_3) X^{\alpha_n + \beta_3} + \dots \end{cases}$$

At each step we must choose the maximum among the head of all streams and then move to the next term in that stream.

• Choosing the maximum from a repeatedly updated collection is efficiently implemented using a **Heap**.

Heap Tricks: Memory Efficient Heap Elements

A heap relies on many comparisons of its elements and essentially random memory access.

- Comparisons are already efficient due to exponent packing.
- It is necessary to only store the product exponent vector, $\alpha_1 + \beta_1$, and the *index* of the corresponding coefficients.
- Reduction of element size allows the entire heap to fit in cache for efficient random random access.

72 bytes



▲□▶ ▲□▶ ▲□▶ ▲□▶ ▲□ ● ● ●

Heap Tricks: Element Chains

In our application, heap elements (monomials) are frequently equal. We can reduce the working size of the heap by $chaining^{[5]}$ equal elements.

- Heap elements found to have the same exponent vector chain together into a linked list instead of inserting a new element.
- Our heap becomes a heap of linked lists.
- Allows extracting many elements for the cost of one extraction.



Benchmarks: $\mathbb{Z}[X]$ with Varying Coefficient Size



◆ロト ◆母 ト ◆ 臣 ト ◆ 臣 - の Q ()・

Benchmarks: $\mathbb{Z}[X]$ with Varying Sparsity



Benchmarks: $\mathbb{Q}[X]$ with Varying Sparsity



Division

◆□▶ ◆□▶ ◆ 臣▶ ◆ 臣▶ ○ 臣 ○ の Q @

The goal of division is to, given c and b, find a and r such that $c = a \cdot b + r$ with lm(b) > lm(r).

For simplicity, a_i , b_i , and c_i in the following discussion are *terms*.

・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・

$$b_1 + b_2) c_1 + c_2 + c_3$$

The goal of division is to, given c and b, find a and r such that $c = a \cdot b + r$ with lm(b) > lm(r).

For simplicity, a_i , b_i , and c_i in the following discussion are *terms*.

・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・

$$b_1 + b_2 \overline{)c_1 + c_2 + c_3}$$

The goal of division is to, given c and b, find a and r such that $c = a \cdot b + r$ with lm(b) > lm(r).

For simplicity, a_i , b_i , and c_i in the following discussion are *terms*.

・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・

$$b_1 + b_2 \frac{a_1}{b_1 + c_2 + c_3} \\ -a_1(b_1 + b_2)$$

The goal of division is to, given c and b, find a and r such that $c = a \cdot b + r$ with lm(b) > lm(r).

For simplicity, a_i , b_i , and c_i in the following discussion are *terms*.

・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・

$$b_1 + b_2 \frac{a_1}{c_1 + c_2 + c_3} = c^{(1)}$$
$$\frac{-a_1(b_1 + b_2)}{c_1^{(2)} + c_2^{(2)}} = c^{(2)}$$

The goal of division is to, given c and b, find a and r such that $c = a \cdot b + r$ with lm(b) > lm(r).

For simplicity, a_i , b_i , and c_i in the following discussion are *terms*.

・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・

$$b_1 + b_2 \frac{a_1 + a_2}{c_1 + c_2 + c_3} = c^{(1)}$$

$$\frac{-a_1(b_1 + b_2)}{c_1^{(2)} + c_2^{(2)}} = c^{(2)}$$

$$\frac{-a_2(b_1 + b_2)}{c_1^{(3)}}$$

The goal of division is to, given c and b, find a and r such that $c = a \cdot b + r$ with lm(b) > lm(r).

For simplicity, a_i , b_i , and c_i in the following discussion are *terms*.

・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・

$$b_1 + b_2 \frac{a_1 + a_2}{c_1 + c_2 + c_3} = c^{(1)}$$

$$-a_1(b_1 + b_2)$$

$$c_1^{(2)} + c_2^{(2)} = c^{(2)}$$

$$-a_2(b_1 + b_2)$$

$$c_1^{(3)} = r$$

The goal of division is to, given c and b, find a and r such that $c = a \cdot b + r$ with lm(b) > lm(r).

For simplicity, a_i , b_i , and c_i in the following discussion are *terms*.

Let's take the following example of basic long division:

$$\begin{array}{rl} a_1 + a_2 \\ b_1 + b_2 \overline{\big)c_1 + c_2 + c_3} = c^{(1)} \\ & \underline{-a_1(b_1 + b_2)} \\ \hline c_1^{(2)} + c_2^{(2)} = c^{(2)} \\ & \underline{-a_2(b_1 + b_2)} \\ \hline c_1^{(3)} = r \end{array} \qquad \bullet \begin{array}{l} c^{(1)} = c \\ \bullet a_i = c_1^{(i)} / b_1 \\ \bullet c^{(i+1)} = c^{(i)} - a_i b \\ \bullet r = c^{(i)} \text{ when } b_1 \text{ cannot} \\ \text{divide } c_1^{(i)} \end{array}$$

・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・
 ・

The goal of division is to, given c and b, find a and r such that $c = a \cdot b + r$ with lm(b) > lm(r).

For simplicity, a_i , b_i , and c_i in the following discussion are *terms*.

Let's take the following example of basic long division:

$$\begin{array}{c} a_1 + a_2 \\ b_1 + b_2 \overline{\big)c_1 + c_2 + c_3} = c^{(1)} \\ \hline \\ -a_1(b_1 + b_2) \\ \hline \\ c_1^{(2)} + c_2^{(2)} = c^{(2)} \\ \hline \\ -a_2(b_1 + b_2) \\ \hline \\ c_1^{(3)} = r \end{array} \qquad \bullet \begin{array}{c} c^{(1)} = c \\ \bullet a_i = c_1^{(i)} / b_1 \\ \bullet c^{(i+1)} = c^{(i)} - a_i b \\ \bullet r = c^{(i)} \text{ when } b_1 \text{ cannot} \\ \text{divide } c_1^{(i)} \end{array}$$

At each step we calculate a full m (size of b) product terms from $a_i \cdot b$ and then perform a subtraction with those m terms.

With some rearrangement of the previous recurrence relation we obtain a simple equation for a_i :

$$a_i = lt\left(c - \sum_{j=1}^{i-1} a_j b\right) / lt(b)$$

This formula has many notable benefits:

- Terms of a are still produced in-order,
- Avoids repeated subtraction and updating of the dividend,
- Reuse multiplication algorithm to obtain ∑^{i−1}_{j=1} a_jb terms in-order.

Sparse Division: Algorithm

Sparse	Division
Spuise	DIVISION

- 1: $a \leftarrow 0$
- 2: while true do
- 3: $\tilde{c} \leftarrow \mathsf{lt}(c-ab)$
- 4: **if** $\mathsf{lt}(b) \nmid \tilde{c}$ **then**
- 5: break
- 6: $a \leftarrow a + (\tilde{c} / \operatorname{lt}(b))$
- 7: end while
- 8: $r \leftarrow c ab$
- 9: return (a, r)
 - For lt(c-ab) it is sufficient to keep track of which terms have already been used instead of doing subtraction.
 - Produce only enough terms of $a \cdot b$ to get the next leading term, \tilde{c} , since a updates continually.
 - $a + (\tilde{c}/\text{lt}(b))$ is only an append as terms are in-order.

Benchmarks: $\mathbb{Z}[X]$ with Varying Sparsity

 $\mathbb{Z}[x, y, z]$ Division Running Time vs Number of Dividend Terms Number of Divisor Terms = n/2, Varying Sparsity, # Coefficient Bits = 32



◆□ > ◆□ > ◆豆 > ◆豆 > ̄豆 _ のへで

Future Work

Future work is focused on improving performance and efficiency.

- Pseudo division (WIP).
- Improved integer arithmetic.
 - $\rightarrow\,$ Dynamic switching between machine-word and multi-precision integers. $^{[3]}$

▲□▶ ▲□▶ ▲□▶ ▲□▶ ▲□ ● ● ●

- Experiment with new exponent packing schemes.
- Investigate different heap implementations.
 → Binary-tree heap, Fibonacci heap, Brodal queue
- Parallelization of algorithms.

References

- M. Monagan and R. Pearce. "Sparse polynomial multiplication and division in Maple 14". In: ACM Communications in Computer Algebra 44.3/4 (2011), pp. 205–209.
- M. Monagan and R. Pearce. "Sparse polynomial division using a heap". In: Journal of Symbolic Computation 46.7 (2011), pp. 807–822.
- [3] M. Monagan and R. Pearce. "The design of Maple's sum-of-products and POLY data structures for representing mathematical objects". In: ACM Communications in Computer Algebra 48.3/4 (2015), pp. 166–186.
- [4] A. D. Hall Jr. "The ALTRAN system for rational function manipulation-a survey". In: Proceedings of the second ACM symposium on Symbolic and algebraic manipulation. ACM. 1971, pp. 153–157.
- [5] M. Monagan and R. Pearce. "Polynomial division using dynamic arrays, heaps, and packed exponent vectors". In: International Workshop on Computer Algebra in Scientific Computing. Springer. 2007, pp. 295–315.
- [6] S. C. Johnson. "Sparse polynomial arithmetic". In: ACM SIGSAM Bulletin 8.3 (1974), pp. 63–71.

Thank you!

Questions?

◆□▶ ◆□▶ ◆ 臣▶ ◆ 臣▶ ○ 臣 ○ の Q @