

基于 64 位寄存器与 SIMD 指令的 H.264/265 NALU 起始码混合搜索算法

白 宇¹
BAI Yu

摘 要

在 H.264 和 H.265 视频编码标准中,网络抽象层单元(NALU)的起始码搜索算法直接决定了解码效率。传统逐字节比对方法因内存访问频繁、分支预测效率低下,存在明显的性能瓶颈。针对该问题,文章提出一种基于 64 位寄存器并行匹配与 SIMD 指令优化的高效混合搜索算法。该算法的创新点主要包括三个方面:一是采用 64 位寄存器并行匹配策略,单次可处理 8 字节数据,并通过位掩码快速定位起始码候选位置;二是引入 SIMD 指令优化,利用 `_mm_movemask_epi8` 指令合并比较结果,有效降低条件分支开销;三是设计数据保序机制,通过顺序解析位掩码,消除传统 SIMD 方案中的排序开销。实验结果表明,在不同分辨率视频场景下,所提算法相较于 FFmpeg 中的传统算法,性能提升幅度达到 17%~34%,且能够自适应检测 H.265 编码标准中定义的四字节起始码。

关键词

H.264; H.265; NALU; 起始码; SIMD; 寄存器优化

doi: 10.3969/j.issn.1672-9528.2026.05.003

0 引言

H.264/AVC 与 H.265/HEVC 是当前主流的两类视频编码标准,二者都使用 NALU(网络抽象层单元)完成视频码流的结构化组织,NALU 配置的起始码可用于界定单元边界,H.264 的起始码为 0x000001, H.265 的起始码为 0x00000001,起始码的检测速度与解码效率关联紧密^[1]。涉及实时视频处理、流媒体及视频监控的相关领域中,检索起始码花费的时间是制约系统性能的关键因素之一^[2-3]。

H.264 的 NALU 头为单字节结构,包含 1 bit 禁止位、2 bit 参考标识与 5 bit 单元类型字段,使用 0x1F 掩码可提取对应类型信息,可承载序列参数集(SPS,类型 7)和图像参数集(PPS,类型 8)等关键数据^[2]。

H.265 对自身的 NALU 头做了扩展,采用双字节结构,包含 1 bit 禁止位、6 bit 类型、6 bit 层级 ID 与 3 bit 时间 ID,要获取类型字段的数值,需代入 $(code \gg 9) \& 0x3F$ 计算得到,还新增了对视频参数集(VPS,类型 32-39)的支持^[4]。这类结构层面的差异,让 H.265 需要兼容四字节起始码的检测流程,整体算法复杂度也有所提升^[3-4]。

FFmpeg 所采用的逐字节比算法存在以下不足:

(1) 内存带宽利用率低:单字节加载模式可能无法充分利用 CPU 缓存;

(2) 分支预测开销大:频繁条件跳转可能使流水线阻塞;

(3) 扩展性不足:无法自动适配 H.265 的 4 字节起始码^[4]。

为解决上述问题,本文提出了融合寄存器级并行与 SIMD 指令集优化^[5]的混合检测算法,可降低内存访问开销,消除冗余条件判断,兼顾低延迟特性,适配高吞吐量要求,完成 NALU 起始码的高效检测。

1 相关工作

1.1 传统方法

FFmpeg 解析 NALU 时,采用滑窗机制逐字节匹配 0x000001 模式,时间复杂度为 $O(n)$ ^[6] 数值相对偏高。核心逻辑如下:

```
vector<int> split_simd_ffmpeg(const uint8_t *data, size_t cb) {  
    vector<int> list_index;  
    const uint8_t *p = data;  
    while (p < data + cb - 3) {  
        if (p[0] == 0 && p[1] == 0 && p[2] == 1) {  
            list_index.push_back(p - data);  
        }  
        p++;  
    }  
}
```

1. 山西大同大学计算机与网络工程学院 山西大同 037009

```

}
return list_index;
}

```

1.2 寄存器优化方法

文献[7]提出基于64位寄存器的并行处理机制(split_nalu),采用位掩码技术实现8字节数据的起始码候选位置检测。例如:

```

uint64_t code = *(uint64_t*)(data + index);
if ((code & 0xFFFFFFF) == 0x01000000) { /* 检测3字节起始码 */ }

```

应用这类方法后内存访问频率有所降低,不过现代CPU的SIMD(单指令多数据流)指令集优势未得到发挥。

1.3 SIMD 优化方法

文献[8]提出的split_nalu_simd属于较早的SIMD实现方案,该方案调用SSE指令集完成16字节数据的并行处理,条件分支判断的额外开销、排序环节的计算延迟会形成制约,让它的性能增益空间比较有限。后续改进方案以位掩码为基础融合多通道比较结果,用逻辑运算消除冗余分支,让算法的运行效率得到提升。目前已公开的研究成果显示,SIMD技术在视频处理领域应用广泛,覆盖帧内预测、运动估计等场景,针对NALU起始码搜索的优化工作,还需要进一步开展探索。

依托前期已完成的工作,本文融合寄存器并行与SIMD指令的优势,设计了一种同时适配性能与通用性的混合搜索算法。

2 优化算法设计

混合搜索算法属于分层检测架构,搭建过程中会结合寄存器级并行处理与SIMD指令集优化两类技术,这套算法设置了两段处理流程,第一阶段通过64位寄存器并行匹配完成候选位置的粗粒度筛选,第二阶段依托SIMD指令集开展细粒度验证。两类技术协同运行的模式,可保障检测精度符合要求,能免去冗余计算带来的额外开销。

2.1 64 位寄存器并行匹配

2.1.1 寄存器并行处理模型

对寄存器并行处理的数学模型做形式化表述:设数据块 B 包含8字节元素 $\{b_0, b_1, \dots, b_7\}$,取H.264起始码模式 $P=0x000001$,小端序下的窗口匹配条件可表示为 $\exists j \in \{0, 1, \dots, 5\}$,使得:

$$(b_j < 16) \mid (b_{j+1} < 8) \mid b_{j+2} = 0x000001 \quad (1)$$

通过位运算优化,可将多位置匹配转化为单次寄存器操作。定义掩码函数 $M(k)=0xFFFFFFFF \ll (k \times 8)$,则候选位置集

合 C 可表示为:

$$C = \{k \mid (B \& M(k)) \gg (k \times 8) = 0x010000\}, k \in \{0, 1, \dots, 5\} \quad (2)$$

式(2)表明通过单次位掩码操作实现了多窗口同步检测,理论上可将比较次数从6次降为1次。

例如:字节块0x00 00 01 23 45 67 89 AB的有效匹配为 $j=0$,即前3字节0x000001。

2.1.2 多模式兼容性设计

为了同时支持H.264的三字节起始码和H.265的四字节起始码检测,算法使用了动态掩码切换机制。定义模式标识符 $\lambda \in \{3, 4\}$,其表示起始码长度,则有效窗口的数量 $N(\lambda)$ 由公式表示为:

$$N(\lambda) = 8 - \lambda + 1 \quad (3)$$

当算法检测到H.265扩展起始码时,则将 λ 设为4,并调整掩码运算参数。通过这种参数化的设计,算法可以自适应不同的编码标准,同时避免了条件分支导致的流水线中断。

2.1.3 边界处理优化

针对跨块起始码问题,传统重叠检测方法需进行两次扫描,会产生一定的额外计算开销。本文算法对此采用了“前瞻性”的缓存机制进行优化:在处理当前块时,预先加载后续块的头部4字节至临时寄存器,形成扩展数据窗口。该机制将跨块检测转化成寄存器内运算,其时间复杂度从 $O(n)$ 降为 $O(1)$ 。具体实现用公式表示为:

$$B = (\text{current_block} \gg (8 \times 6)) \mid (\text{next_block_head} \ll (8 \times 2)) \quad (4)$$

式中: B 构成连续的10字节窗口,将跨块检测转化为寄存器内运算,即在单周期内完成检测。

2.2 SIMD 指令优化

2.2.1 向量化处理模型

SIMD优化阶段采用128位寄存器处理16字节数据块,其并行比较过程可抽象为向量空间运算。设输入向量 $V = (v_0, v_1, \dots, v_{15})$,目标模式检测转化为布尔向量计算:

$$R = (V \gg 2) \wedge (V \gg 2 == 0x01) \quad (5)$$

式中: $V \gg 2$ 表示右移2字节后的向量; $\wedge$ 表示逐元素逻辑与操作。通过_mm_srli_si128指令实现向量移位,配合掩码合成方法,可在一个指令周期内完成全部16个位置的模式匹配检测。

2.2.2 位压缩算法优化

传统SIMD方法在处理结果压缩时需进行多次位提取操作^[8],显然会造成指令级并行度的降低。本文算法采用改进的位平面编码方法,其实质是将128位比较结果压缩为16位整数,过程为:

$$\text{mask} = \sum r_i (r_i \ll i), r_i \in \{0, 1\} \quad (6)$$

式中: r_i 表示第 i 字节的比较结果。该运算使用 `_mm_move_mask_epi8` 指令在单周期内完成位压缩, 较传统移位累加方法提升 4 倍吞吐量。

2.2.3 多条件并行检测

针对 H.264 和 H.265 起始码格式不同的问题, 本文算法使用多级向量比较方法提高效率。首先进行三字节模式检测, 随后通过寄存器复用技术并行执行四字节模式验证。具体步骤包括:

(1) 数据加载: 加载 16 字节到 `__m128i` 寄存器, 使用 `_mm_loadu_si128` 支持非对齐内存访问。

(2) 比较操作: 使用 `_mm_cmpeq_epi8` 比较每个字节是否为 0x00, 生成掩码 `cmp0`。

(3) 右移与二次比较: 使用 `_mm_srli_si128` 右移 2 字节, 生成新寄存器, 再使用 `_mm_cmpeq_epi8` 与 0x01 比较, 生成 `cmp1`。

(4) 位操作: 执行 `_mm_and_si128(cmp0, cmp1)`, 找到 `chunk[m] == 0x00` 且 `chunk[m+2] == 0x01` 的位置。

(5) 压缩结果: 通过使用指令 `_mm_movemask_epi8` 将 128 位结果压缩为 16 位整数, 快速定位候选位置。

(6) 序列化解析: 采用位掩码的序列化解析策略, 相当于自动保存了顺序信息, 避免了常规 SIMD 方法对候选匹配位置的排序需求^[9], 从而实现快速提取有效起始码位置, 同时进行边界条件的处理。

例如: 16 字节数据为 0x00 00 01 23 45 67 89 AB CD EF 00 00 01 34 56 78, 包含 H.264 起始码 (0x000001)。

(1) `cmp0` 标记位置 0、1、10、11 为 0x00。

(2) 右移 2 字节, 令 `cmp1` 为位置 2、12 均等于 0x01。

(3) 合并生成交集, 找到位置 0、10, 即起始码 0x00 00 01。

(4) 针对视频编码标准 H.265 中定义的 0x00 00 00 01 起始码, 本文调整现有处理方法, 新增逐位检索 `chunk[m] == 0x00` 且 `chunk[m+3] == 0x01` 的步骤, 同时确认两个索引位置中间的两个字节取值全部为 0x00, 该调整不会额外增加整体流程的比较步骤。

根据前面的分析, 单周期比较能力可被该方法完整保留, 多条件检测的指令数由 $2N$ 降至 $N+2$ (N 为条件数), 指令缓存的效率得到提升。

2.3 实现细节

2.3.1 寄存器 SIMD 协同机制

两级缓存优化的设计, 让本文提出的混合算法各组件高效配合: 第一级用 64 位寄存器开展块内快速扫描, 得到的候选位置信息存入 L1 缓存; 第二级用 SIMD 引擎从缓存里批量调取候选块, 完成精确验证。该方法共有两方面优势:

(1) 减少 SIMD 部件对内存的随机访问;

(2) 通过硬件进行预读取, 从而减少内存延迟。

2.3.2 分支预测优化

传统算法运行时会因条件判断出现分支误预测问题, 本文算法选用两阶段优化策略:

(1) 静态分支概率分析: 梳理 H.264 与 H.265 的码流特征后, 可确认起始码出现概率低于 0.1%, 后续将检测逻辑重构为无分支预测形式。

(2) 条件转移消除: 将代码结构改成直通式流水线, 用算术移位替换条件语句。候选位置写入操作的示例如下:

$$\text{positions}[\text{index}] = \text{base} + (\text{mask} \& -(\text{mask} \neq 0)) \quad (7)$$

式 (7) 表明通过算术运算模拟条件赋值, 基本消除了流水线清空的风险。

2.3.3 数据对齐优化

非对齐内存访问会导致 SIMD 操作产生周期级延迟。本文算法采用动态对齐补偿:

$$C = 0xFFFF \ll (16 - s \bmod 16) \quad (8)$$

式 (8) 表明当检测到当前数据块偏移量 $s \bmod 16 \neq 0$ 时, 自动生成补偿掩码, 在加载数据后立即应用掩码消除无效字节的影响。该方法在保证处理精度的同时, 较大程度上降低了非对齐访问的性能损耗。

2.3.4 寄存器并行匹配算法

64 位寄存器并行匹配算法伪代码如下:

```
function search_nalu_register(uint8_t* data, size_t len, vector<int> & positions) {
    for (size_t i = 0; i < len - 8; i += 8) {
        uint64_t code = *(uint64_t*)(data + i);
        // H.264: 检查 3 字节起始码 0x000001
        for (int j = 0; j <= 5; j++) {
            uint64_t window = (code >> (j * 8)) & 0xFFFFF;
            if (window == 0x010000) {
                positions.push_back(i + j);
            }
        }
        // H.265: 检查 4 字节起始码 0x00000001
        for (int j = 0; j <= 4; j++) {
            uint64_t window = (code >> (j * 8)) & 0xFFFFFFFF;
            if (window == 0x01000000) {
                positions.push_back(i + j);
            }
        }
    }
    // 边界检查 H.264
    if (i + 8 < len) {
        uint8_t last_two_bytes[2] = {data[i+6], data[i+7]};
```

```

uint8_t next_byte = data[i+8];
if (last_two_bytes[0] == 0x00 && last_two_bytes[1]
== 0x00 && next_byte == 0x01) {
    positions.push_back(i + 6);
}
}
// 边界检查 H.265
if (i + 8 < len) {
    uint8_t last_three_bytes[3] = {data[i+5], data[i+6],
data[i+7]};
    uint8_t next_byte = data[i+8];
    if (last_three_bytes[0] == 0x00 && last_three_
bytes[1] == 0x00 && last_three_bytes[2] == 0x00 && next_byte
== 0x01) {
        positions.push_back(i + 5);
    }
}
}
// 处理最后一个部分块
// ...
return positions;
}

```

2.3.5 SIMD 指令优化算法

SIMD 指令优化算法伪代码如下:

```

function search_nalu_simd(uint8_t* data, size_t len, vec-
tor<int>& positions) {
    __m128i zero = _mm_setzero_si128();
    __m128i one = _mm_set1_epi8(1);
    for (size_t i = 0; i < len - 16; i += 16) {
        __m128i chunk = _mm_loadu_si128((__m128i*)(data
+ i));
        // 比较当前块, 找到 0x00 位置
        __m128i cmp0 = _mm_cmpeq_epi8(chunk, zero);
        // 右移 2 字节后比较, 找到 0x01 位置 (对应 H.264
的模式)
        __m128i shifted = _mm_srli_si128(chunk, 2);
        __m128i cmp1 = _mm_cmpeq_epi8(shifted, one);
        // 交集: chunk[m]==0x00 且 chunk[m+2]==0x01
        __m128i result = _mm_and_si128(cmp0, cmp1);
        // 压缩为位掩码, 快速定位候选位置
        int mask = _mm_movemask_epi8(result);
        // 解析位掩码, 提取有效起始码位置
        while (mask) {
            int pos = __builtin_ctz(mask); // 找到最低位

```

```

// 额外检查: 确保模式正确或处理边界
if (data[i + pos + 3] == 0 || i + pos >= 2) {
    positions.push_back(i + pos);
}
mask &= (mask - 1); // 清除最低位, 继续处理
}
return positions;
}

```

2.3.6 算法调用流程

(1) 通过调用 3.3.4 节所述函数 search_nalu_register 进行初步过滤, 识别可能包含起始码的 8 字节块。

(2) 对过滤后的候选区域, 通过调用上述函数 search_nalu_simd, 利用 SIMD 指令精确检测 16 字节块中的起始码。

(3) 合并结果, 输出得到的所有起始码的位置。

3 实验与结果

3.1 实验环境

硬件: Intel Xeon E5-2678 v3 @2.5 GHz, 64 GB DDR4。

编译选项: g++ -O3 -mavx2 (依赖 AVX2 指令集扩展特性^[10])。

数据集: H.264/265 码流, 分辨率 720~4 096 px, 码率 2~15 Mbit/s。

3.2 性能对比

表 1 展示了不同算法在 4K 视频上的时延对比 (受限于系统 Tickcount 精度, 计时误差 $\pm 10 \mu\text{s}$) :

表 1 不同算法处理 4K 视频的时延对比

算法	平均时延 / μs	加速比 (对比 FFmpeg)
FFmpeg	1 610	1.0×
split_nalu	1 220	1.3×
本文算法	1 070	1.5×

在不同分辨率下, 各算法的性能对比如图 1 所示。




图 1 不同分辨率下的视频处理时延

3.3 复杂度分析

设输入数据长度为 N 字节, 各算法阶段的时间复杂度分析对比如下:

(1) 寄存器匹配阶段: 处理单个 64 位块的耗时为 T_r , 涉及 6 次位运算与 2 次边界检查, 时间复杂度为 $O(N/8 \times T_r)$;

(2) SIMD 验证阶段: 单个 128 位块的处理时长为 T_s , 涉及 4 次向量操作与 1 次位压缩, 时间复杂度为 $O(N/16 \times T_s)$;

(3) 传统算法: 单个字节的处理时长为 T_b , 需完成 3 次比较与 1 次条件跳转, 时间复杂度为 $O(N \times T_b)$ 。

本文对算法完成优化后, 数据量缩减到传统算法的 1/16 到 1/8, T_r 与 T_s 能分别缩减到 3 周期和 5 周期, 传统算法的 T_b 如果分支预测失败可能要 7 到 15 周期。

(4) 空间复杂度分析: 本文算法所占用的寄存器及缓存均为固定数量, 故为 $O(1)$ 。

3.4 鲁棒性分析

实验测试了本文算法在不同视频分辨率下的时延数据:

(1) 低分辨率 (720 px): 比 FFmpeg 算法下降约 17%;

(2) 中分辨率 (1 080 px): 比 FFmpeg 算法下降约 24%;

(3) 高分辨率 (4 096 px): 比 FFmpeg 算法下降约 34%, 这一降幅来自 SIMD 并行化处理和数据局部性的优化。

4 讨论

4.1 算法优势与适用限制

(1) 优势: 算法通过使用不同的掩码, 可同时支持 H.264 和 H.265 的起始码检测。

(2) 适用限制: 分辨率低于 720 px 的低清视频场景中, 由于 CPU 解码的负载不高, SIMD 优化的提升并不明显。同时, 该算法依赖 AVX2 指令集, 无法兼容例如 ARM 这类非 x86 架构平台。

4.2 未来改进方向

(1) 扩展支持 AVX-512 指令集架构^[10], 尝试实现 32 字节级并行运算;

(2) 提升跨平台性, 例如适配 ARM NEON 指令;

(3) 对 8K 超高清视频处理进行研究。

5 结论

本文设计出一种结合 64 位寄存器并行匹配与 SIMD 指令优化的 NALU 起始码搜索算法, 已在 x86 架构下完成了 17%~34% 的性能提升, 可适配 H.264/265 标准的跨版本使用

需求。完成相关测试后, 证实了该算法在实时视频处理中的高效性和鲁棒性, 且在 4K 解码应用场景下表现较好。

参考文献:

- [1] 苏姗, 熊淑华, 何小海, 等. 结合空时域下采样与重建的 H.264/AVC 压缩性能优化 [J]. 电讯技术, 2018, 58(9):1072-1078.
- [2] FFmpeg 开发组. FFmpeg 解码器源码 v4.4 [EB/OL]. [2026-03-05]. <https://ffmpeg.org/releases/ffmpeg-4.4.tar.bz2>.
- [3] Intel Corporation. Intel® 64 and IA-32 Architectures Software Developer's Manual [EB/OL]. [2026-03-05]. <https://software.intel.com/content/www/us/en/develop/articles/intel-sdm.html>.
- [4] ITU-T. H.265(V8) (08/2021) [EB/OL]. [2026-03-05]. <https://www.itu.int/ITU-T/recommendations/rec.aspx?rec=14660&lang=en>.
- [5] 高伟, 赵荣彩, 韩林, 等. SIMD 自动向量化编译优化概述 [J]. 软件学报, 2015, 26(6):1265-1284.
- [6] FFmpeg 开发组. H.264/AVC/MPEG-4 part10 parser [EB/OL]. [2026-03-05]. https://ffmpeg.org/doxygen/4.4/h264_parser_8c_source.html.
- [7] 夏馨缘, 山蕊, 杨坤, 等. 视频阵列处理器 HEVC 去块滤波算法动态重构实现 [J]. 计算机工程与设计, 2023, 44(3):836-844.
- [8] 唐毅欣, 黄晓峰, 唐然, 等. 基于 SIMD 的 AVS3 并行率失真优化量化算法 [J]. 电信科学, 2024, 40(6):114-126.
- [9] 王琦, 韩林, 姚金阳, 等. 不充分 SIMD 向量化技术研究 [J]. 计算机应用与软件, 2018, 35(9):108-112.
- [10] GCC 开发组. Invoking GCC [EB/OL]. [2026-03-05]. <https://github.com/gcc-mirror/gcc/blob/releases/gcc-14.2.0/gcc/doc/invoke.texi>.

【作者简介】

白宇 (1976—), 男, 山西大同人, 硕士, 副教授, 研究方向: 物联网与边缘计算。

(收稿日期: 2025-09-17 修回日期: 2026-05-07)