

فلسفه‌دهسازی اطلاعات

۱۴۰۰-۱۰-۰۰۲-۰۱

بخش سوم



دانشگاه شهید بهشتی
پژوهشگاه فضای مجازی
بهار ۱۴۰۰
امد محمودی ازناوه

(پژوهش‌های متنی بر مبنای
Context-based compressing

فهرست مطالب

- معرفی
- پیش‌بینی متن
- پیش‌بینی با تطابق محدود (ppm)
- - مثال
- Burrows-Wheeler Transform
- Move To Front
- Run Length Encoding
- Associative Coder of Buyanovsky



دانشکده
سینمای
بهره‌برداری

محرفی

- در صورت وجود عده توازن احتمال وقوع داده (skewness)، نسبت فلشرددهسازی افزایش می‌یابد.
- احتمال توزیع داده‌ها در صورت در اختیار داشتن محتوا (در صورت داشتن همیستگی بالا)، دارای عده توازن بیشتری خواهد بود.
 - محتوا باید در کدگذار و کدگشا در اختیار باشد.
- در این دسته از روش‌ها فرض بر این است که در مورد ویژگی‌های آماری دادگان اطلاعات کمی در اختیار داریم.
- از محتوای داده‌های کددشده برای کدگذاری استفاده می‌شود.
 - این شیوه وفقی است.
 - بر اساس مدل‌سازی محتوا عمل می‌کند.
 - به جای این هر نماد به صورت مستقل بررسی شود، با توجه به محتوا مورد بررسی قرار می‌گیرد.
 - برای کدگذاری عمدها از کدگذاری مهاسباتی و یا کدگذاری Huffman استفاده می‌شود.



دانشکده
سینمایی
بهشتی

پیش‌بینی متن- آزمایش ۱

- یک متن در نظر گرفته می‌شود و از یک کاربر می‌خواهید (ادامه‌ی) متن را مدس بزند، در صورت مدس اشتباه نماد درست به او گفته شده و کار ادامه می‌یابد.

(1) THE ROOM WAS NOT VERY LIGHT A SMALL OBLONG

(2) _____ ROO _____ NOT-V _____ I SM _____ OBL _____

(1) READING LAMP ON THE DESK SHED GLOW ON

(2) REA O D SHED-GLO--0--

(1) POLISHED WOOD BUT LESS ON THE SHABBY RED CARPET

(2) P-L-S 0---BU--L-S--0 . . . SH . . . RE --C



- در ۶۹٪ موارد پیش‌بینی درست بوده است.



Shannon, C. E. (1951). "Prediction and entropy of printed English." Bell system technical journal 30(1): 50-64.

پیش‌بینی متن- آزمایش | (ادامه...)

- پنوند که بتوان در کدگشایی (گیرنده) مدرس مشابهی زد، می‌توان برای فشرده‌سازی از پنین پیش‌بینی استفاده کرد:

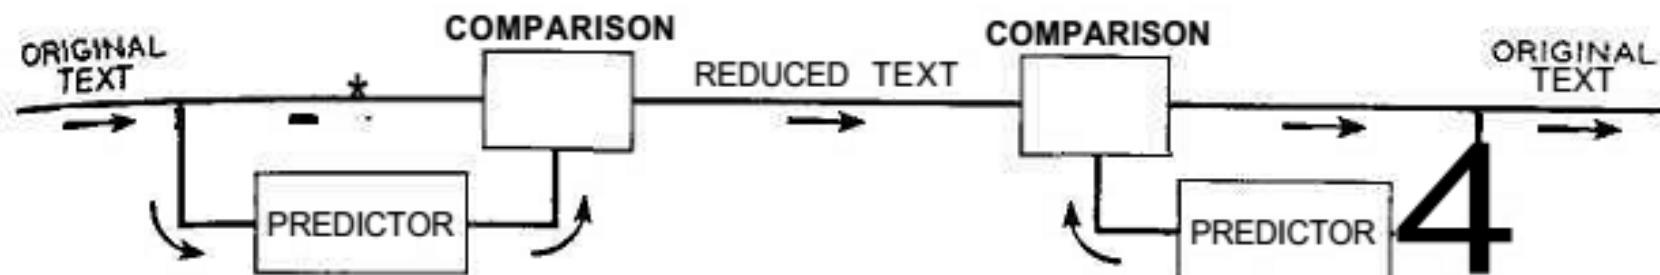


Fig. 2—Communication system using reduced text.



دانشکده
سینمایی
بهشتی

پیش‌بینی متن- آزمایش ۲

- در آزمایش دوچ در صورت مدرس اشتباه کاربر مدرس دیگری را جایگزین می‌کند و این کار آنقدر ادامه می‌یابد تا نماد مورد نظر درست مدرس زده شود.

(1) THERE IS NO REVERSE ON A MOTORCYCLE A
(2) 1 1 1 5 1 1 2 1 1 2 1 1 1 5 1 1 7 1 1 2 1 3 2 1 2 2 7 1 1 1 1 4 1 1 1 1 1 3 1

(1) FRIEND OF MINE FOUND THIS OUT
(2) 8 6 1 3 1 1 1 1 1 1 1 1 1 1 6 2 1 1 1 1 1 1 2 1 1 1 1 1 1 1 1

(1) RATHER DRAMATICALLY THE OTHER DAY
(2) 4 1 1 1 1 1 1 1 1 5 1 1 1 1 1 1 1 1 1 1 1 6 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1

(8)



بر اساس این آزمایش برای نمایش الفبای انگلیسی بین ۰,۶ تا ۰,۷ بیت به ازای هر حرف نیاز دارد.



Shannon, C. E. (1951). "Prediction and entropy of printed English." Bell system technical journal 30(1): 50-64.

پیش‌بینی

- یک راه نگهداری همه‌ی N -تاپی‌ها (N -grams) و مدلس بر اساس احتمال وقوع آن‌هاست.
- در این صورت برای M نماد، محتواهای مرتبه‌ی اول یک جدول M -تاپی، محتواهای مرتبه‌ی دویی یک جدول M^2 -تاپی و ... خواهد بود.
- محتواهای مرتبه‌ی ۵ برای یک الفبای ۲۵۶ تاپی برابر با 256^5 خواهد بود.



دانشکده
سینمای
بهرستانی

پیش‌بینی با تطابق محدود

Prediction with Partial Match (ppm)

- به جای امداده‌سازی و ذخیره‌ی جداول شامل احتمال‌های شرطی، می‌توان این جداول را در طی عملیات کدگذاری آماده نمود.
- بدین‌ترتیب فقط دنباله‌هایی که در متن وجود دارد، ذخیره می‌شوند.
- هر چند این کار نیاز به حافظه (اکاهش) می‌دهد، اما لازم است نمادهایی که تا کنون دیده نشده‌اند، به گونه‌ای مشخص شوند.
 - استفاده از یک نماد (های) یا توالی-گریز (Escape) لازم است.



دانشکده
سینمای
بهشتی

الگوریتم پایه

- در این الگوریتم ابتدا سعی می‌شود پیش‌بینی بر پایه مذاکر طول مورد استفاده انجام شود.
 - مذاکر طول محتوای مورد استفاده از پیش تعیین می‌شود.
- در صورت نبود نماد، در کدگذاری از یک نماد توالی‌گریز (رهایی) استفاده شده و طول محتوای مورد بررسی را یک واحد کاهش داده و همین (وند) را ادامه می‌دهیم.
- در صورتی که نماد پیش از این دیده نشده بود با احتمال $M/1$ کدگذاری انجام می‌شود.



شانگان

محتوا مرتبه ۱

بهشتی

Context of order -1

probability

الگوریتم پایه (ادامه...)

با فرض آن که حرف «a» بناست کد شود.
ابتدا بررسی می‌شود که آیا دنباله‌ی «prob» یا زیر مجموعه‌ی انتهایی آن پیش از این دیده شده است یا نه؟

هدف کد کردن رشته‌ی مقابل است:

-
-
-

در صورت مشاهده «prob»:
• چنان‌چه «prob» مشاهده شده باشد، بر اساس احتمال موجود در این جدول این نماد کد می‌شود و این (ویه) برای حرف بعدی تکرار می‌شود.

محتوا مرتبه ۱۴

در صورت عدم مشاهده «prob»، کاراکتر توالی‌گریز کد می‌شود.

در صورت مشاهده «rob»:

• چنان‌چه «rob» مشاهده شده باشد، بر اساس احتمال موجود در این جدول این نماد کد می‌شود و این (ویه) برای حرف بعدی تکرار می‌شود.

در صورت عدم مشاهده «rob»، کاراکتر توالی‌گریز کد می‌شود.

محتوا مرتبه ۱۳

در صورت مشاهده «ob»:

• چنان‌چه «ob» مشاهده شده باشد، بر اساس احتمال موجود در این جدول این نماد کد می‌شود و این (ویه) برای حرف بعدی تکرار می‌شود.

در صورت عدم مشاهده «ob»، کاراکتر توالی‌گریز کد می‌شود.

محتوا مرتبه ۱۲

در صورت مشاهده «b»:

• چنان‌چه «ba» مشاهده شده باشد، بر اساس احتمال موجود در این جدول این نماد کد می‌شود و این (ویه) برای حرف بعدی تکرار می‌شود.

در صورت عدم مشاهده «ba»، کاراکتر توالی‌گریز کد می‌شود.

در صورتی که «proba» تا به حال دیده نشده باشد، اما «a» پیش از این مشاهد شده باشد، به منزله محتوا مرتبه‌ی صفر کد خواهد شد: بر اساس تعداد کاراکتر مشاهده شده و این (ویه) برای حرف بعدی تکرار می‌شود.

چنان‌چه کاراکتر «a» تاکنون مشاهد نشده باشد، با احتمال $M/1$ کدگذاری انجام می‌شود.

محتوا مرتبه ۱۱

محتوا مرتبه ۰



محتوا مرتبه -۱



مثال

مداکتر طول محتوا: ۲

this is the tight



این کاراکتر باید کد شود



دانشگاه
سینمایی
بهشتی

مثال

مدادکثر طول محتوا: ۲

this is the tight



این کاراکتر باید کد شود

zero-order context	
letter	count
t	1
h	1
i	2
s	2
þ	1
<Esc>	1

first-order context		
context	letter	count
t	h	1
	<Esc>	1
h	i	1
	<Esc>	1
i	s	2
	<Esc>	1
þ	i	1
	<Esc>	1
s	þ	1
	<Esc>	1

second-order context		
context	letter	count
th	i	1
	<Esc>	1
hi	s	1
	<Esc>	1
is	þ	1
	<Esc>	1
þs	i	1
	<Esc>	1
bi	s	1
	<Esc>	1



دانشگاه
سینما
بیهقی

مثال

this is the tight



این کاراکتر باید کد شود

حداکثر طول محتوا: ۲

برای کدگذاری تنها کافیست این جدول مورد استفاده قرار گیرد.



zero-order context	
letter	count
t	1
h	1
i	2
s	2
þ	1
<Esc>	1

first-order context		
context	letter	count
t	h	1
	<Esc>	1
h	i	1
	<Esc>	1
i	s	2
	<Esc>	1
þ	i	1
	<Esc>	1
s	þ	1
	<Esc>	1

second-order context		
context	letter	count
th	i	1
	<Esc>	1
hi	s	1
	<Esc>	1
is	þ	1
	<Esc>	1
sþ	i	1
	<Esc>	1
þi	s	1
	<Esc>	1



دانشکده
بهشتی

مثال

this is the tight



این کاراکتر باید کد شود

حداکثر طول محتوا: ۲

برای کدگذاری تنها کافیست این جدول مورد استفاده قرار گیرد.



zero-order context	
letter	count
t	1
h	1
i	2
s	2
þ	1
<Esc>	1

first-order context		
context	letter	count
t	h	1
	<Esc>	1
h	i	1
	<Esc>	1
i	s	2
	<Esc>	1
þ	i	1
	<Esc>	1
s	þ	1
	<Esc>	1

second-order context		
context	letter	count
th	i	1
	<Esc>	1
hi	s	1
	<Esc>	1
is	þ	1
	<Esc>	1
þs	i	1
	<Esc>	1
bi	s	1
	<Esc>	1

کدگذاری با روش Huffman و یا روش محسوباتی قابل انجام است.
شمارش تعداد وقوع هر حرف در جداول به منظور محسوبه احتمال و یا تابع توزیع تجمعی است.



this is the tight



گاه بعدی به (وزسانی همه جدول هاست



دانشکده
سینمای
بهریتی

this is the tight



گام بعدی به اوزانی همه جدولهاست

zero-order context	
letter	count
t	1
h	1
i	2
s	2
þ	2
<Esc>	1

first-order context		
context	letter	count
t	h	1
	<Esc>	1
h	i	1
	<Esc>	1
i	s	2
	<Esc>	1
þ	i	1
	<Esc>	1
s	þ	2
	<Esc>	1

second-order context		
context	letter	count
th	i	1
	<Esc>	1
hi	s	1
	<Esc>	1
is	þ	2
	<Esc>	1
sþ	i	1
	<Esc>	1
þi	s	1
	<Esc>	1



دانشکده
بهشتی

this is the tight



گام بعدی به دو زمانی همه جدول هاست

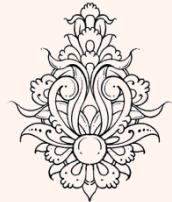
نوبتیه (های)



zero-order context	
letter	count
t	1
h	1
i	2
s	2
þ	2
<Esc>	1

first-order context		
context	letter	count
t	h	1
	<Esc>	1
h	i	1
	<Esc>	1
i	s	2
	<Esc>	1
þ	i	1
	<Esc>	1
s	þ	2
	<Esc>	1

second-order context		
context	letter	count
th	i	1
th	<Esc>	1
hi	s	1
hi	<Esc>	1
is	þ	2
is	<Esc>	1
sþ	i	1
	<Esc>	1
þi	s	1
	<Esc>	1



دانشکده
بهشتی

this is the tight



گام بعدی به (وزسانی هم) جدول هاست

نویسه (های)

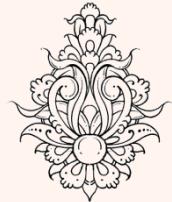
نویسه (های)



zero-order context	
letter	count
t	1
h	1
i	2
s	2
þ	2
<Esc>	1

first-order context		
context	letter	count
t	h	1
	<Esc>	1
h	i	1
	<Esc>	1
i	s	2
	<Esc>	1
þ	i	1
	<Esc>	1
s	þ	2
	<Esc>	1

second-order context		
context	letter	count
th	i	1
	<Esc>	1
hi	s	1
	<Esc>	1
is	þ	2
	<Esc>	1
sþ	i	1
	<Esc>	1
þi	s	1
	<Esc>	1



دانشکده
سینمایی
بهشتی

this is the tight

برای کدگذاری این جدول مورد استفاده قرار می‌گیرد.

نویسه‌هایی



zero-order context

letter	count
t	1
h	1
i	2
s	2
þ	2
<Esc>	1

کام بعدی به (وزسانی
همه جدول‌هاست

first-order context

context	letter	count
t	h	1
	<Esc>	1
h	i	1
	<Esc>	1
i	s	2
	<Esc>	1
þ	i	1
	<Esc>	1
s	þ	2
	<Esc>	1

کام بعدی به (وزسانی همه جدول‌هاست

نویسه‌هایی

second-order context

context	letter	count
th	i	1
	<Esc>	1
hi	s	1
	<Esc>	1
is	þ	2
	<Esc>	1
sþ	i	1
	<Esc>	1
þi	s	1
	<Esc>	1



دانشکده
سینمایی

this is the tight

zero-order context	
letter	count
t	2
h	1
i	2
s	2
þ	2
<Esc>	1

first-order context		
context	letter	count
t	h	1
	<Esc>	1
h	i	1
	<Esc>	1
i	s	2
	<Esc>	1
	i	1
þ	t	1
	<Esc>	1
s	þ	2
	<Esc>	1

second-order context		
context	letter	count
th	i	1
	<Esc>	1
hi	s	1
	<Esc>	1
is	þ	2
	<Esc>	1
	i	1
sþ	t	1
	<Esc>	1
bi	s	1
	<Esc>	1



ڈانشکارہ
بھیٹی

this is the tight

zero-order context	
letter	count
t	2
h	1
i	2
s	2
þ	2
<Esc>	1

first-order context		
context	letter	count
t	h	1
	<Esc>	1
h	i	1
	<Esc>	1
i	s	2
	<Esc>	1
	i	1
þ	t	1
	<Esc>	1
s	þ	2
	<Esc>	1

second-order context		
context	letter	count
th	i	1
	<Esc>	1
hi	s	1
	<Esc>	1
is	þ	2
	<Esc>	1
	i	1
sþ	t	1
	<Esc>	1
bi	s	1
	<Esc>	1



ڈانشکارہ
بھیٹی

this is the tight



برای کدگذاری این جدول مورد استفاده قرار می‌گیرد.



zero-order context

letter	count
t	2
h	1
i	2
s	2
þ	2
<Esc>	1

کام بعدی به دو زمانی
همه جدول‌هاست

first-order context

context	letter	count
t	h	1
	<Esc>	1
h	i	1
	<Esc>	1
i	s	2
	<Esc>	1
þ	i	1
	t	1
s	<Esc>	1
	þ	2
<Esc>		

second-order context

context	letter	count
th	i	1
	<Esc>	1
hi	s	1
	<Esc>	1
is	þ	2
	<Esc>	1
sþ	i	1
	t	1
<Esc>		
	s	1
bi	<Esc>	1



دانشکده
سینمایی

The Exclusion Principle

هر چه جدول‌ها کوچک‌تر باشند فشرده‌سازی بهتر انجام می‌شود. به عنوان مثال در کدهای محاسباتی باعث می‌شود طول بازه به تعداد کم‌تر شکسته شود و در نتیجه طول زیربازه‌ها افزایش می‌یابد و در این حالت تعداد بیت بیشتری قابل نمایش خواهد بود.

probability

first-order context		
context	letter	count
b	l	5
	o	3
	a	4
	r	4
	e	2
	<Esc>	1

second-order context		
context	letter	count
ob	l	10
	o	3
<Esc>		1



دانشگاه
سینمایی

The Exclusion Principle

هر چه جدول‌ها کوچک‌تر باشند فشرده‌سازی بهتر انجام می‌شود. به عنوان مثال در کدهای محاسباتی باعث می‌شود طول بازه به تعداد کم‌تر شکسته شود و در نتیجه طول زیربازه‌ها افزایش می‌یابد و در این حالت تعداد بیت بیشتری قابل نمایش خواهد بود.

probability

نویسه (هایی)



first-order context		
context	letter	count
b	l	5
	o	3
	a	4
	r	4
	e	2
	<Esc>	1

second-order context		
context	letter	count
ob	l	10
	o	3
	<Esc>	1



دانشکده
سینمایی
بهشتی

The Exclusion Principle

هر چه جدول‌ها کوچک‌تر باشند فشرده‌سازی بهتر انجام می‌شود. به عنوان مثال در گذهای محاسباتی باعث می‌شود طول بازه به تعداد کم‌تر شکسته شود و در نتیجه طول زیربازه‌ها افزایش می‌یابد و در این حالت تعداد بیت بیشتری قابل نمایش خواهد بود.

probability

نویسه (هایی)



first-order context		
context	letter	count
b	l	5
	o	3
	a	4
	r	4
	e	2
	<Esc>	1

second-order context		
context	letter	count
ob	l	10
	o	3
	<Esc>	1



دانشکده
سینمایی
بهشتی

The Exclusion Principle

هر چه جدول‌ها کوچک‌تر باشند فشرده‌سازی بهتر انجام می‌شود. به عنوان مثال در کدهای محاسباتی باعث می‌شود طول بازه به تعداد کم‌تر شکسته شود و در نتیجه طول زیربازه‌ها افزایش می‌یابد و در این حالت تعداد بیت بیشتری قابل نمایش خواهد بود.

probability

نویسه (هایی)



first-order context		
context	letter	count
	l	5
	o	3
b	a	4
	r	4
	e	2
	<Esc>	1

second-order context		
context	letter	count
	l	10
ob	o	3
	<Esc>	1



دانشگاه
سینمایی

The Exclusion Principle

هر چه جدول‌ها کوچک‌تر باشند فشرده‌سازی بهتر انجام می‌شود. به عنوان مثال در گذهای محاسباتی باعث می‌شود طول بازه به تعداد کم‌تر شکسته شود و در نتیجه طول زیربازه‌ها افزایش می‌یابد و در این حالت تعداد بیت بیشتری قابل نمایش خواهد بود.

probability

نویسه (هایی)



first-order context		
context	letter	count
b	l	1
	o	1
	a	4
	r	4
	e	2
	<Esc>	1

second-order context		
context	letter	count
ob	l	10
	o	3
	<Esc>	1



دانشکده
سینمایی

پیش‌بینی با تطبیق محدود(جمع‌بندی)

- برای کدگذاری نویسه‌ی (های) (وش‌های متعددی) مطرح شده است. در اینجا به $ppma$ اشاره شد.
- افزایش طول محتوی باعث افزایش احتمال می‌شود اما باید توجه داشت که می‌تواند منجر به تعداد زیادی نماد (های) شود.
- نسبت به LZ کندتر است.
- به حافظه‌ی زیادی احتیاج دارد.
- نمونه‌های پیاده‌سازی جدید آن در زمره‌ی بهترین (وش‌ها) برای فشرده‌سازی متن‌های شامل زبان طبیعی است.



دانشکده
سینمایی
بهشتی

فشرده‌سازی با BWT

The Burrows-Wheeler Transform

- از محتوا استفاده می‌کند.
- سال ۱۹۹۴ مطرح شد.
- تبدیل مورد استفاده در سال ۱۹۸۳ توسط wheeler تبدیل مطرح شده بود.
- برای متن مناسب است.
- لازم است کل داده‌ها پیش از کدگذاری در اختیار باشد.
- در *bzip2* استفاده شده است.

Burrows, M. and D. J. Wheeler (1994). A block-sorting lossless data compression algorithm, Digital Systems Research Center.



The Burrows-Wheeler Transform

- یک دنباله شامل $N-1$ نماد را در نظر بگیرید.
- این دنباله را هر بار به صورت دورانی یک واحد (به سمت/چپ) راست شیفت داده و $N-1$ دنباله‌ی حاصل را به صورت «الفبایی» مرتب کنید.
- خروجی تبدیل، نمادهای آفر دنباله‌های مرتب شده و موقعیت دنباله‌ی اصلی است.

Lexicographical order



دانشکده
سینما
و تئاتر

BW - تبدیل

this is the

دنباله‌های حاصل از پرفس دنباله‌ی ۹۰۹دی:

00	<i>t</i>	<i>h</i>	<i>i</i>	<i>s</i>	\emptyset	<i>i</i>	<i>s</i>	\emptyset	<i>t</i>	<i>h</i>	<i>e</i>
01	<i>h</i>	<i>i</i>	<i>s</i>	\emptyset	<i>i</i>	<i>s</i>	\emptyset	<i>t</i>	<i>h</i>	<i>e</i>	<i>t</i>
02	<i>i</i>	<i>s</i>	\emptyset	<i>i</i>	<i>s</i>	\emptyset	<i>t</i>	<i>h</i>	<i>e</i>	<i>t</i>	<i>h</i>
03	<i>s</i>	\emptyset	<i>i</i>	<i>s</i>	\emptyset	<i>t</i>	<i>h</i>	<i>e</i>	<i>t</i>	<i>h</i>	<i>i</i>
04	\emptyset	<i>i</i>	<i>s</i>	\emptyset	<i>t</i>	<i>h</i>	<i>e</i>	<i>t</i>	<i>h</i>	<i>i</i>	<i>s</i>
05	<i>i</i>	<i>s</i>	\emptyset	<i>t</i>	<i>h</i>	<i>e</i>	<i>t</i>	<i>h</i>	<i>i</i>	<i>s</i>	\emptyset
06	<i>s</i>	\emptyset	<i>t</i>	<i>h</i>	<i>e</i>	<i>t</i>	<i>h</i>	<i>i</i>	<i>s</i>	\emptyset	<i>i</i>
07	\emptyset	<i>t</i>	<i>h</i>	<i>e</i>	<i>t</i>	<i>h</i>	<i>i</i>	<i>s</i>	\emptyset	<i>i</i>	<i>s</i>
08	<i>t</i>	<i>h</i>	<i>e</i>	<i>t</i>	<i>h</i>	<i>i</i>	<i>s</i>	\emptyset	<i>i</i>	<i>s</i>	\emptyset
09	<i>h</i>	<i>e</i>	<i>t</i>	<i>h</i>	<i>i</i>	<i>s</i>	\emptyset	<i>i</i>	<i>s</i>	\emptyset	<i>t</i>
10	<i>e</i>	<i>t</i>	<i>h</i>	<i>i</i>	<i>s</i>	\emptyset	<i>i</i>	<i>s</i>	\emptyset	<i>t</i>	<i>h</i>



دانشکده
بهشتی

ادامه‌ی مثال

داده‌ها به صورت الفبایی مرتب هیشوند.

F

0	ø	i	s	ø	t	h	e	t	h	i	s
1	ø	t	h	e	t	h	i	s	ø	i	s
2	e	t	h	i	s	ø	i	s	ø	t	h
3	h	e	t	h	i	s	ø	i	s	ø	t
4	h	i	s	ø	i	s	ø	t	h	e	t
5	i	s	ø	i	s	ø	t	h	e	t	h
6	i	s	ø	t	h	e	t	h	i	s	ø
7	s	ø	i	s	ø	t	h	e	t	h	i
8	s	ø	t	h	e	t	h	i	s	ø	i
9	t	h	e	t	h	i	s	ø	i	s	ø
10	t	h	i	s	ø	i	s	ø	t	h	e

L

خروجی: *sshtth ii e 10*

- این تبدیل «برگشت‌پذیر» است؛ خروجی برای یافتن ورودی کفايت هیگزند.



مثال - تبدیل معکوس

چگونه می‌توان از خروجی به واردی (سیدی)؟

- تمام نمادها در رشته‌ی خروجی وجود دارد.

L : sshthbiibe

- می‌توان با توجه به رشته‌ی *L*، رشته‌ی *F* را به دست آورد، با مرتب کردن الفبایی رشته.

F : bbehhiiissst

0	b	i	s	b	t	h	e	t	h	i	s
1	b	t	h	e	t	h	i	s	b	i	s
2	e	t	h	i	s	b	i	s	b	t	h
3	h	e	t	h	i	s	b	i	s	b	t
4	h	i	s	b	i	s	b	t	h	e	t
5	i	s	b	i	s	b	t	h	e	t	h
6	i	s	b	t	h	e	t	h	i	s	b
7	s	b	i	s	b	t	h	e	t	h	i
8	s	b	t	h	e	t	h	i	s	b	i
9	t	h	e	t	h	i	s	b	i	s	b
10	t	h	i	s	b	i	s	b	t	h	e



دانشکده
سینمایی

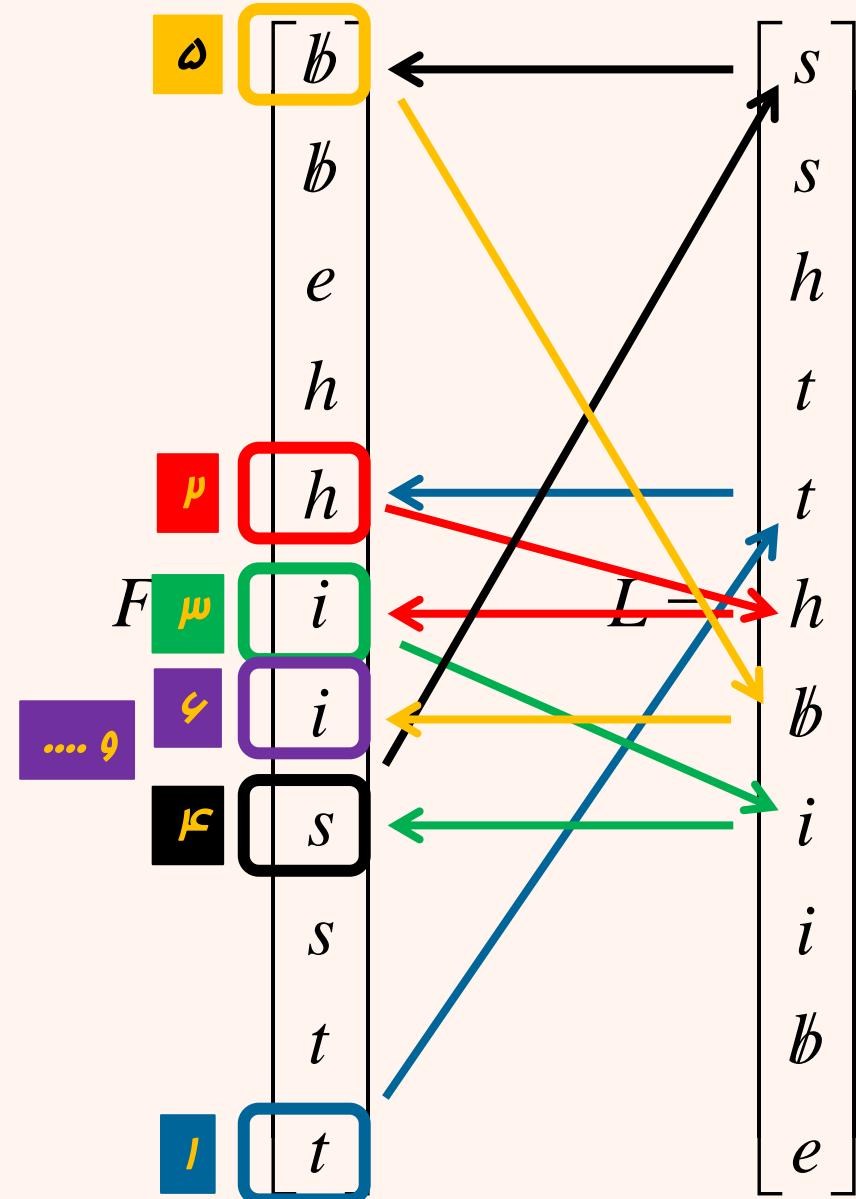
اداھی مثال



دانشکده
بهشتی

۳۹

t h i s b i ...



تبديل BWT و فشردهسازی

- تاکنون عملای هیچگونه فشردهسازی انجام نشده است.
- در حقیقت با این تبدیل، دنباله‌ای به دست می‌آید که به نسبت بیشتری قابل فشردهسازی خواهد بود.
 - در زبان انگلیسی واژه «the» زیاد استفاده می‌شود، با این روش بعد از عملیات پرفس و مرتب‌سازی، چندین رشته خواهیم داشت که با «he» شروع می‌شود و به «t» ختم می‌شود.
 - در ۷ تعداد زیادی «t» در کنار هم قرار خواهد گرفت.
 - در این حالت رشته‌ای خواهیم داشت که «به صورت محلی همگن» است.
 - برای پاسخ مناسب به چندده کیلوبایت داده نیاز دارد.

locally homogeneous



دانشگاه
جمهوری اسلامی
جمهوری اسلامی

Move-to-Front Coding(MTF)

book stack

- می‌توان آن را پیش‌پردازش الگوریتم‌های گدگذاری دانست.
- در این شیوه کاراکترهای متوالی شبیه به هم با کاراکتر «۰» کد می‌شوند.
- عملکرد به این ترتیب است که الفبا به صورت یک لیست در نظر گرفته می‌شود.
- عنصر بالا با شاخص صفر نشان داده می‌شود و سایر عناصر به ترتیب با اعداد طبیعی
- آخرین عنصری که دیده شده است به بالای لیست منتقل می‌شود.
- بدین ترتیب قسمت‌های همگن با یک‌سری «۰» پشت سر هم مدل می‌شود.



دانشگاه
سینما
بهشتی

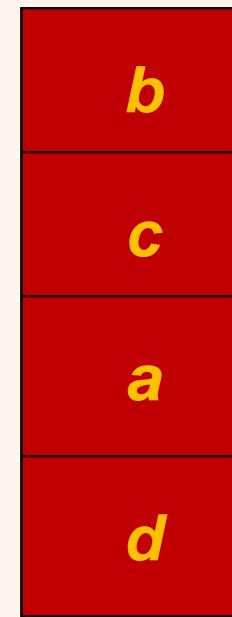
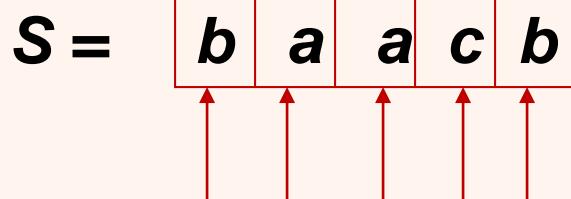
مثال ۱

$$A = \{a, b, c, d\}$$

الفبا

پیشنهای
نمادهای
دیده شده

(شنبه ۹ دی ۹۷)



$$MTF(S) =$$

1	1	0	2	2
---	---	---	---	---

کد خروجی



دانشکده
سینمای
بهریتی

Presentation of

A Simpler Analysis of Burrows-Wheeler Based Compression

Haim Kaplan, Shir Landau, Elad Verbin

فسرده سازی

Move to Front

مثال ۲

abracadabra

a,b,r,c,d



دانشکده
سینمای
بهریتی

۱۴۸

فسرده‌سازی

Haim Kaplan and Elad Verbin

Move to Front

مثال م ({اداھ...})

<u>a</u> bracadabra		<u>a</u> ,b,r,c,d
a <u>b</u> racadabra	0	a, <u>b</u> ,r,c,d



دانشکده
سینمایی
بهشتی

۱۴

فسرده‌سازی

Haim Kaplan and Elad Verbin

<u>a</u> bracadabra		<u>a</u> ,b,r,c,d
a <u>b</u> racadabra	0	a, <u>b</u> ,r,c,d
ab <u>r</u> acadabra	0,1	b,a, <u>r</u> ,c,d



دانشکده
سینمایی
بهشتی

<u>a</u> bracadabra		a,b,r,c,d
a <u>b</u> racadabra	0	a, <u>b</u> ,r,c,d
ab <u>r</u> acadabra	0,1	b,a, <u>r</u> ,c,d
abr <u>a</u> cadabra	0,1,2	r,b, <u>a</u> ,c,d



دانشکده
سینمایی
بهشتی

<u>a</u> bracadabra		a,b,r,c,d
a <u>b</u> racadabra	0	a, <u>b</u> ,r,c,d
ab <u>r</u> acadabra	0,1	b,a, <u>r</u> ,c,d
abr <u>a</u> cadabra	0,1,2	r,b, <u>a</u> ,c,d
abr <u>c</u> adabra	0,1,2,2	a,r,b, <u>c</u> ,d

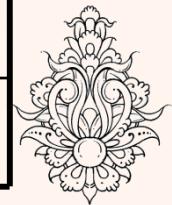


دانشکده
سینمایی

<u>a</u> bracadabra		a,b,r,c,d
a <u>b</u> racadabra	0	a, <u>b</u> ,r,c,d
ab <u>r</u> acadabra	0,1	b,a, <u>r</u> ,c,d
abr <u>a</u> cadabra	0,1,2	r,b, <u>a</u> ,c,d
abr <u>c</u> adabra	0,1,2,2	a,r,b, <u>c</u> ,d
abr <u>c</u> adabra	0,1,2,2,3	c, <u>a</u> ,r,b,d
abraca <u>d</u> abra	0,1,2,2,3,1	a,c,r,b, <u>d</u>



<u>a</u> bracadabra		a,b,r,c,d
a <u>b</u> racadabra	0	a, <u>b</u> ,r,c,d
ab <u>r</u> acadabra	0,1	b,a, <u>r</u> ,c,d
abr <u>a</u> cadabra	0,1,2	r,b, <u>a</u> ,c,d
abr <u>c</u> adabra	0,1,2,2	a,r,b, <u>c</u> ,d
abr <u>c</u> adabra	0,1,2,2,3	c, <u>a</u> ,r,b,d
abr <u>c</u> adabra	0,1,2,2,3,1	a,c,r,b, <u>d</u>
abracadabra	0,1,2,2,3,1,4,1,4,4,2	



بعد از این مرامل دنباله دارای تعداد زیادی صفر فواهد بود و بدین ترتیب آنروپی کاهش می‌یابد.

دانشکده
سینمایی
بهشتی

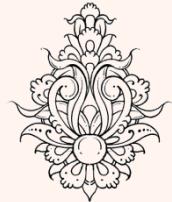
Run Length Encoding(RLE)

- در این شیوه از تعداد تکرار نمادهای متوالی برای کدگذاری استفاده می‌شود:

$abbaaacccca \Rightarrow (a, 1), (b, 3), (a, 2), (c, 4), (a, 1)$

- در فرمت فشردهسازی تصویر jpeg از این شیوه بهره‌گرفته شده است.

- بدین‌ترتیب شمای کلی سیستم فشردهسازی به صورت زیر خواهد بود:



- در این شیوه، یک واژه‌نامه از محتوای (شئی) دیده شده تهیه می‌شود.
 - از یک پنجه‌هی لغزندۀ شبیه LZ77 استفاده می‌کند.
 - بخش چپ پنجه Content و بخش راست آن Context نامیده می‌شود.
- واژه‌نامه نیز دارای دو بخش مشابه است:
 - محتوای زمینه (دیده شده)
 - (شئی) تالی محتوای زمینه

مقایسه از راست به چپ

- جستجو بهترین تطبیق (بر اساس ترتیب الفبایی)
- سپس content مدخل‌های همسایه نیز مورد بررسی قرار می‌گیرند (طولانی‌ترین).

مقایسه از چپ به راست



دانشکده
سینمایی
بهشتی



دانشگاه
شهرورد

- یک سهتایی به عنوان خروجی ارسال می‌شود:
 $(d, count, ch)$
 - « d »: فاصله‌ی بین بهترین context و بهترین content –
 - « $count$ »: تعداد نمادهای منطبق –
 - « ch »: اولین نماد منطبق نشده در پنجه‌ی look-ahead –
- واژه‌نامه به روز می‌شود.
- content یافت شده یکی از مدخلهای مرتبط است و ممکن است مدخلهای همسایه‌ی آن مربوط به content‌های مرتبط‌تر باشد.
- همیشه طولانی‌ترین content منجر به بهترین فشرده‌سازی نمی‌شود، در برخی موارد انتخاب عبارات کوتاه نزدیک به context ممکن است منجر به کدگذاری بهتری شوند.

در مورد جزئیات پیاده‌سازی ACB اطلاعات چندانی در دست نیست!

محتوا و رشتهای تالی

پنجمراهی لغزان مانند LZ77

text: swiss miss is missing

context content

با هر بار شیفت یک context-content جدید به دست می‌آید:

ss m|iss is mis

Salomon, D. (2012). [Data Compression: The Complete Reference](#), Springer
Berlin Heidelberg.



محتوا و رشته‌ی تالی

پنجه‌ی لغزان مانند LZ77

text: swiss miss is missing

context content

با هر بار شیفت یک context-content پدیده به دست می‌آید:

ss m|iss is mis

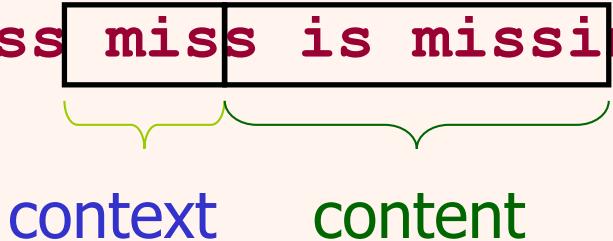
s mi|ss is miss



محتوا و رشته‌ی تالی

پنجمین لغزان مانند LZ77

text: swiss miss is missing



با هر بار شیفت یک context-content جدید به دست می‌آید:

ss m|iss is mis
s mi|ss is miss
mis|s is missi



واژه‌نامه

بدین ترتیب واژه‌نامه به دست می‌آید (برای هفت کاراکتر).



بفُش **context** از راست به چپ مرتب شده است.
بعد از پردازش هر کاراکتر یک مدخل به واژه‌نامه افزوده می‌شود.
برای این که در گذگش، واژه‌نامه به همین شیوه قابل ساخت باشد،
آنها رشته‌ی موجود در **search buffer** در نظر گرفته می‌شود.



..... گویا اینجا پردازش شده است

مثال-کدگذاری

swiss m iss is missing

current context

وضعیت جاری واژه‌نامه:

- | | |
|---|---------------|
| 1 | ...swiss m |
| 2 | ...swi_ ss m |
| 3 | ...s wiss m |
| 4 | ...swis s m |
| 5 | ...swiss m |
| 6 | ...sw i ss m |

۱ نزدیک‌ترین context در واژه‌نامه جستجو شود:

۲ فاصله‌ی نزدیک‌ترین content بین مدخل دوچ و سوم یافته شده در واژه‌نامه به دست آید.

مدخل ششم، فاصله: چهار

۴-۲



دانشکده
سینمایی
بهشتی

مثال-کدگذاری (ادامه...)

swiss m|iss is missing
current context

- وضعیت چاری و ازهناهه:
- 1 ...swiss |m
 - 2 ...swi_|ss m
 - 3 ...s|wiss m
 - 4 ...swis|s m
 - 5 ...swiss| m
 - 6 ...sw|i_ss m

یافتن طول content بگسان

m

چها

یافتن اولین نماد ناهمسان با content

c

تولید سه تایی مرتب

o

(6-2, 4, 'i')

معادل (شتهی پنجه تایی زیر)

iss i

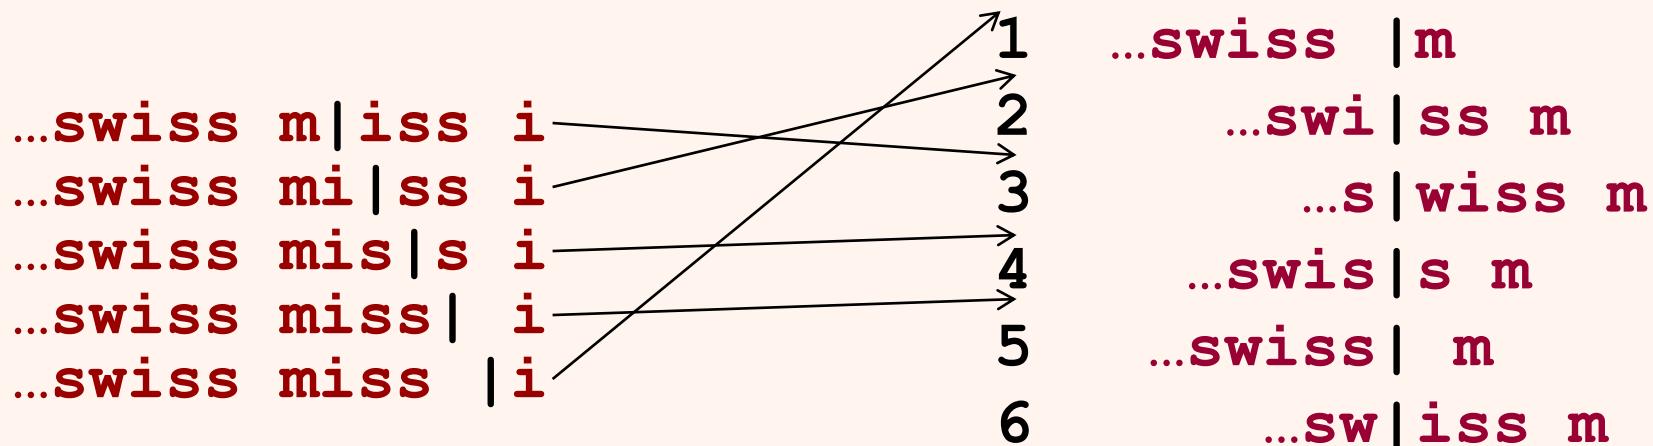


مثال-گذاری (ادامه...)

۴

وازدحامه بروز شود:

context: swiss m
content: iss i



دانشکده
بهشتی

واژه‌نامه به اوزرسانی شده

- 1 ...swiss miss | i
- 2 ...swiss | miss i
- 3 ...swiss mi|ss i
- 4 ...swi|ss miss i
- 5 ...swiss m|iss i
- 6 ...s|wiss miss i
- 7 ...swiss mis|s i
- 8 ...swis|s miss i
- 9 ...swiss miss| i
- 10 ...swiss| miss i
- 11 ...sw|iiss miss i



پیان یک صفحه

ڈائسکاؤنٹ
بھیٹی

واژه‌نامه به اوزرسانی شده

- 1 ...swiss miss | i
- 2 ...swiss | miss i
- 3 ...swiss mi|ss i
- 4 ...swi|ss miss i
- 5 ...swiss m|iss i
- 6 ...s|wiss miss i
- 7 ...swiss mis|s i
- 8 ...swis|s miss i
- 9 ...swiss miss| i 6
- 10 ...swiss| miss i
- 11 ...sw|iss miss i

۷ اینجا پردازش شده است

swiss miss i | s missing

current context

(8-2, 6, 'i')



دانشکده
سینمایی

مثال-کدگذاری (ادامه...)

- همین مراحل ادامه می‌یابد:

...s wiss_ miss_is_ missi	1	...swiss_ miss_is_ missi
...sw iss_ miss_is_ missi	2	...swiss_ miss_is_ missi
...swi ss_ miss_is_ missi	3	...swiss_ miss_is_ missi
...swis s_ miss_is_ missi	4	...swiss_ miss_i s_ missi
...swiss_ miss_is_ missi	5	...swiss_ miss_is_ missi
...swiss_ miss_is_ missi	6	...swiss_ miss_is_ missi
...swiss_m iss_is_ missi	7	...swiss_ miss_is_ missi
...swiss_mi ss_is_ missi	8	...swiss_ miss_is_ missi
...swiss_mis s_is_ missi	9	...swiss_m iss_is_ missi
...swiss_miss i_is_ missi	10	...s wiss_ miss_is_ missi
...swiss_miss_ is_ missi	11	...swiss_ miss_is_ missi
...swiss_miss_is s_ missi	12	...swiss_ miss_is_ missi
...swiss_miss_is_ missi	13	...swiss_ mis s_is_ missi
...swiss_miss_is_ missi	14	...swis s_ miss_is_ missi
...swiss_miss_is_m issi	15	..swiss_ miss_is_ missi
...swiss_miss_is_mi ssi	16	...swiss_ miss_ is_ missi
...swiss_miss_is_mi ssi	17	...swiss_ miss_is_ missi
...swiss_miss_is_mi ssi	18	...sw iss_ miss_is_ missi

swiss miss is missi|ng

current context

(0, 0, 'n')

و به همین ترتیب



دانشکده
سینمایی
بهشتی

مثال-کدگشایی

context: swiss m
content: unkown
(4,4,i)

d=4 → “iss”

i='i' → “ iss i ”

وضعیت کنونی واژه‌نامه:

- | | |
|---|---------------|
| 1 | ...swiss m |
| 2 | ...swi ss m |
| 3 | ...s wiss m |
| 4 | ...swis s m |
| 5 | ...swiss m |
| 6 | ...sw iss m |
- 4 {

نزدیک‌ترین context در واژه‌نامه جستجو شود.

بر اساس کد، content ب دست آید.

(شنبه) مشابه بر اساس کد مشخص شود.

کاراکتر سوچ به (شنبه) کدگشایی شده اضافه شود.
واژه‌نامه به (وز) شود.

۱

۲

۳

۴

۵



مثال

$S = mississippi$

- در ابتدا وارد نامه خالی است.

mississippi



$(0,0,m)$

	Context	Content
1	Empty	Empty



دانشکده
سینمایی
بهشتی

مثال

$S = mississippi$

mississippi



$(0,0,m)$

$(0,0,i)$

	Context	Content
1	Empty	Empty



دانشکده
بهشتی

مثال

$S = mississippi$

mississippi



$(0,0,m)$

$(0,0,i)$

$(0,0,s)$

	Context	Content
1	m	i



دانشکده
بهشتی

مثال

$S = mississippi$

mississippi



$(0,0,m)$

$(0,0,i)$

$(0,0,s)$

$(-1,1,i)$

	Context	Content
1	mi	s
2	m	is



دانشکده
پژوهشی

مثال

$S = mississippi$

mississippi



$(0,0,m)$

$(0,0,i)$

$(0,0,s)$

$(-1,1,i)$

$(0,3,p)$

	Context	Content
1	m	issi
2	mi	ssi
3	mis	si
4	miss	i



دانشکده
سینمایی
بهشتی

$S = mississippi$

mississippi



$(0,0,m)$

$(0,0,i)$

$(0,0,s)$

$(-1,1,i)$

$(0,3,p)$

$(-1,1,i)$

	Context	Content
1	mi	ssissip
2	missi	ssip
3	mississi	p
4	m	ississip
5	mis	sissip
6	missis	sipp
7	miss	issip
8	mississ	ip



مثال

$S = mississippi$

mississippi



$(0,0,m)$

$(0,0,i)$

$(0,0,s)$

$(-1,1,i)$

$(0,3,p)$

$(-1,1,i)$

	Context	Content
1	mi	ssissip
2	missi	ssip
3	mississi	p
4	m	ississip
5	mississip	pi
6	mississipp	i
7	mis	sissip
8	missis	sipp
9	miss	issip
10	mississ	ip



دانشکده
سینمایی