

로그 수집·인덱싱

인덱스·역색인 · 로그 스키마 · 정규화 · _bulk 적재

01

인덱스·역색인

문서·인덱스·샤드와 검색을 가속하는 역색인

02

로그 스키마

실습에서 쓸 필드 레퍼런스와 타입

03

정규화

이질적 로그를 공통 필드명으로 매핑

04

_bulk 적재

문서를 직접 넣고 인덱스·매핑 확인

S2

로그 수집·인덱싱

세션 개요와 학습 목표

로그가 어떻게 문서로 저장되고 검색 가능한 형태가 되는지 익힌다.

이 세션에서 얻는 것

- **인덱스·역색인**: 문서가 인덱스에 담기고 역색인이 만들어져 검색이 빨라지는 원리를 설명할 수 있다.
- **로그 스키마**: 실습에서 쓸 필드 레퍼런스와 text·keyword 타입의 차이를 구분해 이해한다.
- **정규화와 적재**: 원본 로그를 공통 필드로 정규화하고 _bulk API로 직접 적재해 본다.

실습 준비

- **공용 서버 접속**: 개인 PC 설치 없이 브라우저로 공용 대시보드에 접속하고 Dev Tools Console을 연다.
- **기본 인덱스**: loggen이 채우는 logs-demo-* 인덱스가 이미 있어 바로 매핑·문서를 확인할 수 있다.

● 인덱스

○ 스키마

○ 정규화

○ 적재

○ 정리

S2

로그 수집·인덱싱

인덱스·문서·샤드

검색 엔진의 저장 단위를 문서·인덱스·샤드·매핑으로 나눠 이해한다.

핵심 단위

- **문서**: 로그 한 건이 하나의 JSON 문서이며 @timestamp-event-client_ip 같은 필드로 구성된다.
- **인덱스**: 유사한 문서를 모아 담는 컨테이너로, 이 랩은 logs-demo-YYYY.MM.DD를 쓴다.
- **샤드**: 인덱스를 물리적으로 나눈 조각으로, 데이터를 분산 저장해 대용량과 병렬 검색을 지원한다.
- **매핑**: 각 필드의 타입(date-keyword-ip-number-text)을 정의해 검색·집계 동작을 결정한다.

인덱스 수명주기

- **일자별 분할**: 인덱스명이 날짜로 끝나 하루치씩 쌓이므로 오래된 인덱스를 통째로 관리·삭제하기 쉽다.
- **패턴으로 통합**: logs-demo-* 와일드카드로 여러 날 인덱스를 한 번에 검색·집계한다.

● 인덱스

○ 스키마

○ 정규화

○ 적재

○ 정리

S2

로그 수집·인덱싱

역색인과 분석기(토큰화)

분석기가 text를 토큰으로 쪼개 역색인에 담아야 검색이 가능하다.

```
[원본 문서]
doc1: url = "/search?id=1"
doc2: url = "/login"

[분석기(analyzer) - text 토큰화]
"/search?id=1"
-> ["search", "id", "1"]
"/login"
-> ["login"]

[역색인 - 토큰 → 문서 목록]
"search" -> [doc1]
"id"      -> [doc1]
"login"   -> [doc2]

질의 url:search
→ 곧바로 [doc1] 반환
```

● 인덱스

○ 스키마

○ 정규화

○ 적재

○ 정리

동작 원리

- **분석기**: text 필드 값을 소문자·토큰 단위로 쪼개 부분 검색과 전문 검색을 가능하게 한다.
- **keyword**: 분석하지 않고 원문을 통째로 저장해 정확 일치와 집계에 쓴다.
- **역색인**: 토큰에서 문서 목록으로 거꾸로 가리켜 전체 스캔 없이 검색을 끝낸다.

S2

로그 수집·인덱싱

text 필드 vs keyword 필드

같은 값이라도 타입에 따라 검색·집계 동작이 완전히 달라진다.

항목	text vs keyword
저장방식	text=토큰화 / keyword=원문
용도	text=전문검색 / keyword=정확일치·집계
집계	text=불가 / keyword=가능
예시필드	url·user_agent=text / event·geo.country=keyword
멀티필드	url.keyword 서브필드로 둘 다

집계 규칙

- **.keyword 필수**: 정렬·집계엔 원문을 통째로 가진 keyword 필드가 필요하다.
- **Terms 오류**: text 필드를 Terms 집계에 쓰면 "invalid for Terms aggregation" 오류가 난다.
- **멀티필드**: url은 검색용 text, url.keyword는 집계용으로 함께 매핑된다.

● 인덱스

○ 스키마

○ 정규화

○ 적재

○ 정리

S2

로그 수집·인덱싱

○ 인덱스

● 스키마

○ 정규화

○ 적재

○ 정리

로그 스키마 필드 레퍼런스

모든 쿼리는 아래 필드명을 정확히 써야 검색이 된다.

필드	타입	예시	의미
@timestamp	date	2026-07-08T04:12:33Z	이벤트 발생 시각(UTC)
event	keyword	access · attack · auth_fail	이벤트 분류(핵심)
client_ip	ip	203.0.113.7	요청 출발 IP
geo.country	keyword	KR · US · CN · RU	접속 국가 코드
http.method	keyword	GET · POST · PUT	HTTP 메서드
http.status	number	200 · 401 · 403 · 404 · 500	응답 상태코드
http.bytes	number	200 ~ 40000	응답 크기(byte)
url	text	/login · /.env	요청 경로(+payload)
response_ms	number	2 ~ 900	응답 시간(ms)
user_agent	text	Chrome · curl · sqlmap	User-Agent 문자열
attack_type	keyword	sqli · xss · path_traversal	공격 유형

S2

로그 수집·인덱싱

핵심 필드 심화

필드 간 관계와 조건부 존재를 알아야 쿼리가 정확해진다.

조건부 필드

- **event**: access·attack·auth_fail로 나뉘는 최상위 분류 필드로 대부분의 쿼리가 여기서 출발한다.
- **attack_type·severity**: event가 attack인 문서에만 존재하며 공격 유형과 심각도를 담는다.
- **user·geo.country**: user는 auth_fail 시 로그인 시도 계정, geo.country는 ISO2 국가코드를 담는다.

필드명 정확성

- **오타 주의**: attack_type을 attacktype으로 잘못 쓰면 결과가 0건이 되며 오류 없이 조용히 빈 화면만 나온다.
- **중첩 표기**: geo.country·http.status처럼 점(.)으로 중첩 구조 하위 필드를 지정한다.

○ 인덱스

● 스키마

○ 정규화

○ 적재

○ 정리

S2

로그 수집·인덱싱

☐ 인덱스☒ 스키마☐ 정규화☐ 적재☐ 정리

실제 문서 예시(JSON)

이벤트 유형에 따라 존재하는 필드가 달라진다.

```
# 인증 실패 문서 - user 필드 존재
{
  "@timestamp": "2026-07-08T04:12:33.482Z",
  "event": "auth_fail",
  "client_ip": "203.0.113.7",
  "geo": { "country": "RU" },
  "http": { "method": "POST", "status": 401, "bytes": 512 },
  "url": "/login",
  "response_ms": 88,
  "user_agent": "python-requests/2.31",
  "user": "admin"
}
# 공격 문서 - attack_type.severity 존재, url에 payload
{
  "@timestamp": "2026-07-08T04:13:01.107Z",
  "event": "attack", "attack_type": "sqli", "severity": "high",
  "client_ip": "10.0.0.9",
  "url": "/search?id=1' OR '1'='1",
  "http": { "method": "GET", "status": 500 }
}
```


S2

로그 수집·인덱싱

로그 정규화

서로 다른 원본 로그를 하나의 공통 스키마로 맞추는 과정이다.

정규화란

- **필드 매핑**: 원본 로그 라인을 파싱해 `client_ip`·`http.status` 같은 공통 필드명으로 옮기는 것이 정규화다.
- **타입 강제**: 파싱 시 `status`는 숫자, `@timestamp`는 날짜로 타입을 맞춰야 범위·정렬 쿼리가 동작한다.
- **중첩 표현**: `http.method.geo.country`처럼 관련 필드를 객체로 묶어 구조를 명확히 한다.

정규화의 이점

- **공통 스키마**: ECS 유사 스키마를 쓰면 방화벽·웹서버·인증 등 이질적 소스를 한 스키마로 검색한다.
- **재사용성**: 쿼리·대시보드·알럿 규칙을 소스가 달라도 그대로 재사용할 수 있다.

○ 인덱스

○ 스키마

● 정규화

○ 적재

○ 정리

S2

로그 수집·인덱싱

- 인덱스
- 스키마
- 정규화
- 적재
- 정리

수집 파이프라인

수집기가 원본 로그를 파싱·정규화해 엔진으로 전송한다.

수집기	특징
Logstash	ELK · 풍부한 필터·변환
Beats	ELK · 경량 전송 에이전트
Data Prepper	OpenSearch 수집 파이프라인
Fluent Bit	경량 · 컨테이너 환경
Ingest Pipeline	엔진 내부 전처리

선택 관점

- **역할**: 수집기는 파싱·정규화·전송을 담당해 원본 로그를 문서로 바꾼다.
- **조합**: 경량 수집기로 모으고 엔진 Ingest Pipeline으로 전처리하는 조합이 일반적이다.

S2

로그 수집·인덱싱

○ 인덱스

○ 스키마

○ 정규화

● 적재

○ 정리

_bulk 로 문서 적재

Dev Tools Console에서 여러 문서를 한 번에 넣는다.

```
# 문서 여러 개 한 번에 적재 (_bulk)
# NDJSON: (액션 줄) + (소스 줄) 을 쌍으로 반복
POST logs-demo-2026.07.09/_bulk
# 액션 줄 - {"index":{}} 는 새 문서 색인
{ "index": {} }
# 소스 줄 - 인증 실패 문서
{ "@timestamp":"2026-07-09T04:00:00Z","event":"auth_fail","client_ip":"10.0.0.9","user":"admin","url":"/login","http":{"method":"POST","status":401} }
# 액션 줄
{ "index": {} }
# 소스 줄 - SQLi 공격 문서
{ "@timestamp":"2026-07-09T04:00:01Z","event":"attack","attack_type":"sqli","severity":"high","client_ip":"10.0.0.9","url":"/search?id=1' OR '1'='1","http":{"method":"GET","status":500} }
# 각 줄은 한 줄로 작성, 마지막 줄 끝에 개행 필요
```

S2

로그 수집·인덱싱

☐ 인덱스☐ 스키마☐ 정규화☒ 적재☐ 정리

인덱스·매핑 확인

적재 후 필드 타입과 문서 수가 의도대로인지 확인한다.

```
# 매핑 확인 - 각 필드의 타입 점검
GET logs-demo-*/_mapping
#   event.geo.country 는 keyword, url-user_agent 는 text 인지 확인

# 문서 수 확인 - 적재가 반영됐는지
GET logs-demo-*/_count

# 문서 1건 조회 - 실제 필드 구조 확인
GET logs-demo-*/_search
{ "size": 1 }

# 인덱스 목록 - 일자별 인덱스와 문서 수·용량
GET _cat/indices/logs-demo-*?v
#   docs.count 가 늘었으면 적재 성공
```

S2

로그 수집·인덱싱

인덱스 패턴 logs-demo-*

여러 일자 인덱스를 하나로 묶어 Discover에서 검색하게 한다.

인덱스 패턴이란

- **와일드카드 통합:** logs-demo-* 패턴이 여러 일자 인덱스를 하나로 묶어 한 번에 검색·집계한다.
- **기본값 지정:** 이 랩은 logs-demo-*가 기본 인덱스 패턴으로 지정돼 있어 바로 Discover에서 시작한다.
- **시간 필드:** 패턴 생성 시 시간 필드를 @timestamp로 지정해 시간 범위 검색을 활성화한다.

문제 해결

- **UTC 주의:** 로그는 UTC로 저장되므로 데이터가 안 보이면 시간 범위를 넓혀 Refresh한다.
- **자동 복구:** 패턴이 없다는 안내가 뜨면 대개 10분 내 복구되며, 급하면 Dashboards Management에서 생성한다.

○ 인덱스

○ 스키마

○ 정규화

● 적재

○ 정리

S2

로그 수집·인덱싱

세션 정리와 다음 예고

로그가 문서로 저장되고 검색 가능해지는 전 과정을 묶어 정리한다.

기억할 것

- **역색인**: 분석기가 text를 토큰으로 쪼개 역색인에 담아야 대량 로그도 즉시 검색·집계된다.
- **스키마**: event가 핵심 분류 필드이며 집계엔 keyword(또는 .keyword) 타입이 필요하다.
- **정규화·적재**: 원본을 공통 필드로 정규화하고 _bulk로 적재한 뒤 매핑·문서 수를 확인한다.

다음 예고 — 세션 3

- **KQL 검색**: Discover 검색창에 KQL을 입력해 이벤트·상태코드·공격 유형을 필터링한다.
- **연산자**: AND·OR·범위·와일드카드로 조건을 조합해 의심 트래픽을 추려낸다.

○ 인덱스

○ 스키마

○ 정규화

○ 적재

● 정리