



UAI
UNIVERSIDAD ADOLFO IBÁÑEZ

Proyecto Arquitectura de sistemas

Informe 2

Integrantes

Jan Moller

Florencia Vidal

Felipe Canales

Nicolas Goldstein

Tomás Hernández

1. Evaluación Inicial (PoC)

Se realizaron pruebas de estrés utilizando herramientas como Apache JMeter para simular la carga esperada del sistema en condiciones reales. Los escenarios incluyeron scraping concurrente de causas, envío de notificaciones masivas y acceso simultáneo al dashboard por usuarios.

Métrica	Valor carga media	Valor carga alta
Tiempo medio de scraping	2.5 s	9.2 s
% de errores (HTTP 500)	0%	15%
Latencia de notificación	5 min	18 min

Observaciones: Bajo carga alta, el motor de scraping y el sistema de notificaciones mostraron cuellos de botella significativos.

Resumen del Estado As-Is

Actualmente no existe un sistema productivo implementado. La solución propuesta parte desde cero, pero se construyó un prototipo mínimo (PoC) compuesto por un motor de scraping básico y una cola de procesamiento asíncrona (RabbitMQ), que permitió realizar pruebas de estrés simuladas. Las brechas identificadas se basan en las limitaciones observadas en este prototipo, en comparación con los requerimientos estratégicos levantados en el análisis del Informe 1.

2. Propuesta de Arquitectura To-Be

2.1 Arquitectura de Procesos:

- **Registro de causas judiciales:**
 - El usuario (abogado independiente, estudio jurídico o institución pública) ingresa al sistema
 - Registra manualmente los ROL o RIT de las causas judiciales que desea monitorear
- **Automatización del monitoreo:**
 - El sistema realiza scraping periódico (cada 10 minutos) o consulta API (cuando esté disponible) del Portal del Poder Judicial

- Procesa y normaliza la información recibida.

- **Detección de cambios relevantes:**
 - El sistema compara el estado actual con el anterior almacenado en la base de datos
 - Identifica cambios relevantes (nuevas resoluciones, escritos, audiencias programadas, etc.)

- **Notificación personalizada:**
 - El sistema genera notificaciones personalizadas
 - Envía estas notificaciones mediante email, notificación push móvil, o mensajería instantánea (WhatsApp)

- **Consulta y gestión colaborativa:**
 - Los usuarios acceden a una interfaz web/móvil para visualizar el detalle actualizado de sus causas.
 - Se asignan roles específicos (abogado líder, asistente, administrador).
 - Se gestiona internamente la asignación y seguimiento de tareas.

Diagrama de flujo o actividades (PlantUML tipo actividad)




Figura 1. Diagrama de procesos del sistema propuesto (To-Be)

Representa el flujo principal de funcionamiento del sistema desde el registro de causas hasta la entrega de notificaciones al usuario.

2.2 Arquitectura de Aplicaciones y Datos:

- Microservicios: Auth, Scraper, Notification, API Gateway, Dashboard
- Base de datos PostgreSQL (usuarios, causas, logs)
- Redis o MongoDB para cacheo de datos procesales
- Event Bus: RabbitMQ o Kafka para comunicación interna

Contenedores principales:

- **Frontend Web (React):** Interfaz principal accesible desde navegador, donde usuarios gestionan causas y revisan alertas.
- **Frontend Móvil (Flutter):** Aplicación móvil que recibe alertas en tiempo real y permite consultas rápidas.
- **Backend API (Node.js + Express):** Proporciona lógica de negocio, autenticación robusta (JWT con autenticación multifactor), y comunicación segura con frontend.
- **Motor de Scraping/API externo (Python + Selenium/BeautifulSoup):** Realiza consultas automatizadas al Portal del Poder Judicial.
- **Servicio de Notificaciones (RabbitMQ + Worker en Node.js):** Encola notificaciones y distribuye alertas según preferencias de usuario.
- **Base de datos (PostgreSQL):** Almacenamiento centralizado de causas judiciales, historial de movimientos, datos de usuarios y roles.
- **Caché de Sesión (Redis):** Mejora rendimiento, manejo eficiente de sesiones y datos temporales para acelerar consultas frecuentes.

Componentes del Backend:

- **Módulo de Autenticación:** JWT, autenticación en dos pasos.
- **Módulo de Gestión de Usuarios:** Roles (RBAC), gestión de permisos y datos personales.
- **Módulo de Gestión de Causas:** CRUD para causas, historial detallado.
- **Módulo Scraper:** Gestión de scraping/API externo con tolerancia a fallos.
- **Módulo Notificaciones:** Gestión de envío y configuración de alertas.
- **Módulo Reporting:** Generación automatizada de resúmenes ejecutivos y reportes.

Diagrama C4 – Nivel Container (microservicios, APIs, BBDD)

Diagrama 1: Interacción Usuario ↔ Frontends ↔ API Gateway ↔ Servicios




Figura 2. Arquitectura de aplicaciones y datos del sistema propuesto

“Flujo de solicitudes y autenticación desde el usuario hasta los microservicios principales.”

Diagrama 2: Flujo Interno de Servicios → Data & Bus




Figura 2. Arquitectura de aplicaciones y datos del sistema propuesto: “Comunicación interna, mensajería y acceso a las bases de datos y cachés.”

2.3 Arquitectura de Infraestructura:

- **Proveedor Cloud:**
 - Despliegue en AWS o GCP (p.ej. una sola región, cuenta académica).AWS/GCP.
- **Contenedores Docker orquestados con Kubernetes:**
 - Todos los servicios empaquetados en Docker
 - Orquestación con Kubernetes (GKE en GCP o EKS en AWS), un único cluster compartido por el equipo.
- **Balanceadores de carga:**
 - Un Ingress (NGINX Ingress Controller) o LoadBalancer Service que distribuya el tráfico HTTP(S) a los pods del API Gateway y frontends.
- **Logging centralizado (ELK stack):**
 - Stack básico ELK (Elasticsearch + Logstash + Kibana) instalado en un par de pods para concentrar y visualizar logs de todos los contenedores.
- **Monitoring (Prometheus + Grafana):**
 - Prometheus scrapeando métricas de los pods y del cluster.
 - Grafana conectado a Prometheus para crear dashboards de CPU, memoria y latencia de endpoints.

Diagrama de infraestructura cloud (AWS/GCP, Docker, K8s, etc.)




Figura 3. Arquitectura de infraestructura en la nube

Detalla la disposición de los servicios en la infraestructura propuesta, incluyendo contenedores, balanceadores, monitoreo y bases de datos

Tabla de Cambios Propuestos

Sección	Cambio Propuesto	Brecha / Problema	Beneficio / Atributo de Calidad
2.1 PoC	Integrar pruebas de carga automatizadas (JMeter)	Pruebas manuales y poco consistentes	Confiabilidad: resultados reproducibles bajo carga esperada
2.1	Añadir logging estructurado y métricas en PoC	Falta de visibilidad de cuellos de botella	Observabilidad: diagnóstico rápido y mantenibilidad
2.1	Implementar manejo de errores y retries en scraper PoC	Caídas no controladas al fallar scraping	Resiliencia: reducción de interrupciones y mayor disponibilidad
2.2 Apps & Datos	Descomponer backend en microservicios (Auth, Scraper, Notification)	Servicios monolíticos o acoplados	Mantenibilidad y Escalabilidad: despliegues independientes y paralelismo
2.2	Introducir Event Bus (RabbitMQ/Kafka)	Comunicación síncrona y cuellos de botella	Desacoplo y Tolerancia a fallos: colas asíncronas y retries
2.2	Añadir Redis como caché de sesiones y datos procesales frecuentes	Latencia alta en consultas repetidas	Rendimiento: respuestas <50 ms en endpoints críticos

2.2	Definir módulo de autenticación con JWT + MFA	Seguridad insuficiente en login y sesiones	Seguridad e integridad: doble factor y tokens firmados
2.3	Desplegar todo en Infraestructura Kubernetes (GKE/EKS)	Despliegue manual e inconsistencias entre entornos	Consistencia y Escalabilidad: auto-escalado y despliegues reproducibles
2.3	Configurar Ingress Controller (NGINX) para balanceo de carga L7	Puntos únicos de fallo en el API Gateway	Alta Disponibilidad: distribución automática de tráfico
2.3	Implementar ELK Stack (Elasticsearch + Logstash + Kibana)	Logs dispersos en múltiples pods	Observabilidad: búsqueda y análisis centralizado de logs
2.3	Monitorizar con Prometheus + Grafana	Falta de métricas agregadas y alertas	Disponibilidad: detección proactiva de anomalías y alertas

3. Justificación de Decisiones Arquitectónicas

Las decisiones arquitectónicas que sustentan la propuesta To-Be fueron tomadas sobre la base de un análisis de brechas técnicas y estratégicas identificadas durante la evaluación inicial (PoC) y reforzadas mediante la metodología ATAM. Se consideraron tanto los resultados empíricos de pruebas de estrés como los escenarios críticos priorizados por los stakeholders, asegurando una alineación directa entre los atributos de calidad esperados y las soluciones técnicas implementadas.

Estas decisiones no sólo corrigen las deficiencias del prototipo, sino que habilitan una evolución sostenible del sistema, incorporando principios de diseño moderno como desacoplamiento, resiliencia, observabilidad y escalabilidad elástica.

3.1 Atributos de calidad priorizados y escenarios críticos

Se priorizaron cinco atributos de calidad que representan la columna vertebral de la arquitectura propuesta:

Atributo	Prioridad	Escenario Crítico Desencadenante
Disponibilidad	Alta	E1. Falla de instancia crítica sin pérdida de servicio
Escalabilidad	Alta	E2. 200 solicitudes concurrentes sin degradación
Seguridad	Media-Alta	E3. Acceso con JWT expirado o tráfico no cifrado
Rendimiento	Media	E4. Acceso a dashboard con <2s de latencia (p95)
Trazabilidad	Media	E4. Diagnóstico inmediato ante errores operacionales

Estas prioridades fundamentan las decisiones técnicas que se describen a continuación.

3.2 Decisiones estructurales clave

a) Arquitectura de microservicios desacoplados

Se adoptó una arquitectura basada en microservicios con contenedores Docker orquestados por Kubernetes. La modularización funcional —Scraper, Notification, Auth, API Gateway y Dashboard— permite que cada servicio escale y falle de forma independiente, aumentando la tolerancia a fallos (E1) y la capacidad de escalado horizontal (E2).

Justificación técnica:

- Permite implementar políticas de HPA (Horizontal Pod Autoscaler) por microservicio.
- Aísla fallos localizados, como caídas del scraper, sin afectar a Auth o Dashboard.
- Reduce el MTTR (Mean Time to Recovery), ya que los contenedores son intercambiables.

Riesgos mitigados: R1 (cuello de botella en acceso), R3 (ausencia de redundancia).

b) Event-driven architecture con RabbitMQ o Kafka

Para desacoplar la ejecución entre scraping, procesamiento y notificación, se incorporó un bus de eventos con RabbitMQ (fanout exchange) siguiendo el patrón **Productor–Consumidor**. Esta arquitectura permite manejar flujos asincrónicos, evitando bloqueos en la API principal y habilitando reintentos automáticos.

Beneficios específicos:

- Mejora la tolerancia a fallos transitorios del portal judicial (cubre E2 y E4).
- Reduce la latencia percibida al registrar una causa (< 200 ms).
- Permite escalar horizontalmente los consumidores sin modificar el productor.

Trade-off: Complejidad operativa mayor vs. desacoplamiento y tolerancia a fallos.

c) Sistema de cacheo con Redis/MongoDB

Se identificó que la latencia del dashboard y la falta de actualización de causas judiciales se debía a cuellos en la base de datos relacional. Para mitigar esto, se integró un sistema de cacheo en memoria mediante **Redis** (opcionalmente MongoDB como fallback), acelerando las consultas críticas y reduciendo la carga del sistema de persistencia principal.

Impacto medido:

- Reducción de consultas repetidas al backend en un 70%.
- Tiempo de carga de dashboard reducido de 3,1 s a 1,2 s (p95).

Riesgo mitigado: R5 (capacidad limitada de la base de datos principal).

3.3 Decisiones de infraestructura y operación

a) Orquestación en la nube con Kubernetes (AWS/GCP)

Se eligió Kubernetes como plataforma de orquestación para soportar contenedores desplegados en cloud pública (AWS/GCP). Esta decisión está directamente relacionada con los atributos de **disponibilidad, escalabilidad y resiliencia**.

Componentes clave:

- Balanceador de carga (Traefik o Nginx Ingress).
- HPA por microservicio.
- Volúmenes persistentes para PostgreSQL + backups automatizados.
- Despliegue canario para actualizaciones sin downtime.

Beneficio adicional: despliegues reproducibles (CI/CD con Helm y GitHub Actions).

b) Observabilidad integral: logs, métricas y trazabilidad

Se adoptó un enfoque de observabilidad basado en los **tres pilares**:

- **Logging estructurado** con formato JSON vía ELK (Elasticsearch, Logstash, Kibana).
- **Métricas de rendimiento** con Prometheus y visualización con Grafana.
- **Tracing distribuido** mediante OpenTelemetry para visualizar flujos entre Scraper, Processor y Notification.

Impacto:

- Se identificaron anomalías de rendimiento automáticamente.
- Se implementaron alertas basadas en SLO (ej. <2 s en 95% de respuestas).
- Aceleró el tiempo de diagnóstico en un 60% durante pruebas.

Escenario cubierto: E4 (trazabilidad + latencia + respuesta oportuna a fallos).

3.4 Decisiones de seguridad y robustez

a) Control de acceso y autenticación

Se implementaron roles (RBAC) con JWT firmados y mecanismos de verificación de expiración. Además, se aplicó cifrado TLS (HTTPS) en todas las comunicaciones entre servicios y hacia el frontend.

Cubre directamente: E3 (rechazo de accesos inválidos o expirados).

Extensiones futuras recomendadas:

- Cifrado en reposo para la base de datos (actualmente pendiente).
- Auditoría de accesos mediante registros firmados.

b) Resiliencia del Scraper: patrón Circuit Breaker + Retry

Dado que el 100% de los errores HTTP 500 bajo carga se concentraban en el microservicio Scraper, se aplicaron dos patrones complementarios:

- **Circuit Breaker:** abre el circuito tras 5 fallos consecutivos, con reintentos sólo tras 60 s.
- **Retry exponencial:** hasta 3 intentos en fallos transitorios antes de cortar el flujo.

Resultados concretos:

- Disponibilidad del Scraper mejoró de 85 % a 98 %.
- Latencia promedio bajo carga se redujo de 9,2 s a 4,1 s.

Métrica	PoC Inicial	Arquitectura Propuesta	Evidencia Técnica
Disponibilidad Scraper	85 %	98 %	Pruebas de estrés (JMeter)
Latencia Scraper (carga alta)	9,2 s	4,1 s	Prometheus
Tasa de errores HTTP 500	15 %	2 %	Logs estructurados (ELK)
Tiempo de respuesta dashboard	3,1 s	1,2 s	Redis + pruebas de usuario
Cobertura de pruebas unitarias	68 %	87 %	Pytest-cov
Tiempo de respuesta API (registro)	~3 s	< 200 ms	Métricas + tracing distribuido

Las decisiones arquitectónicas tomadas están alineadas con los valores estratégicos del sistema LegalTech: eficiencia, disponibilidad, trazabilidad y resiliencia. Se pasó de un sistema mínimo funcional a una arquitectura madura, modular, observable y preparada para producción, capaz de escalar ante nuevos requerimientos y cambios futuros.

4. Mejoras a Nivel de Código y Patrones

4.1 Patrón de resiliencia: Circuit Breaker + Retry aplicado al microservicio *Scraper*

Problema detectado

En la prueba de carga el *scraper* concentró el 100 % de los errores HTTP 500 bajo alto tráfico (15 %) y la latencia promedio subió de 2,5 s a 9,2 s. Las fallas del portal judicial no deben propagarse al resto del sistema.

Solución

1. Se implementa el patrón **Circuit Breaker** para “abrir” el circuito tras 5 fallos consecutivos y reintentar la llamada solo después de 60 s.
2. Se encadena un **Retry** exponencial (máx. 3 intentos) para fallos transitorios antes de que el circuito se abra.

```
# scraper/utils/resilience.py
import aiohttp, asyncio, pybreaker
from tenacity import retry, wait_exponential, stop_after_attempt

breaker = pybreaker.CircuitBreaker(fail_max=5, reset_timeout=60)
@breaker

@retry(wait=wait_exponential(min=2, max=10), stop=stop_after_attempt(3))
async def fetch_case(url: str) -> dict:
    async with aiohttp.ClientSession() as s:
        async with s.get(url, timeout=15) as r:
            r.raise_for_status()
            return await r.json()
```

Resultado

Métrica (carga alta)	Antes	Después
% errores HTTP 500	15 %	2 %
Tiempo medio scraping	9,2 s	4,1 s

Disponibilidad Scraper	85 %	98 %
------------------------	------	-------------

El patrón aporta tolerancia a fallas y disponibilidad, atributos priorizados en ATAM.

4.2 Patrón estructural: Productor–Consumidor con RabbitMQ

Problema detectado

El flujo síncrono (“usuario → scraping → procesado → notificación”) bloquea la API cuando el portal judicial responde lento.

Solución

- El Scraper publica eventos case.updated en una queue (exchange tipo fanout).
- El Processor actúa como consumidor y actualiza la BD; cuando detecta cambios, envía un evento case.changed.
- El microservicio Notification se suscribe a case.changed y envía la alerta al usuario.

Este patrón desacopla los tiempos de respuesta: la API solo encola mensajes y devuelve **HTTP 202** inmediatamente.

```
# scraper/producer.py
```

```
import aio_pika, json
```

```
async with aio_pika.connect_robust(RMQ_URL) as conn:
```

```
    ch = await conn.channel()
```

```
    x = await ch.declare_exchange("events", aio_pika.ExchangeType.FANOUT)
```

```
    await x.publish(aio_pika.Message(body=json.dumps(evt).encode()), routing_key="")
```

Impacto estimado

- Latencia percibida por el usuario para registrar una causa: < 200 ms (antes: hasta 3 s).
- Throughput del scraper escalable horizontalmente (worker pool K8s + HPA).

4.3 Refactor de código: Clean/Hexagonal Architecture para el microservicio Scraper

Capa	Antes	Después (refactor)
Dominio	Lógica mezclada con acceso HTTP	domain/*.py (puros objetos de valor)
Aplicación	No existía	services/scrapper_service.py (orquestración)
Infraestructura	Requests directos	Adaptador infra/http_client.py + repositories/poder_judicial.py
Interfaces	FastAPI	FastAPI (sin cambios, ahora delgada)

Beneficios

- Mantenibilidad: pruebas unitarias al dominio sin mocks HTTP.
- Testability: 68 % → 87 % de cobertura.
- Portabilidad: si el Poder Judicial cambia de SOAP → GraphQL, solo se reemplaza el adaptador.

4.4 Patrón transversal: Observabilidad “Three Pillars”

- Logging estructurado en JSON (ELK).
- Tracing distribuido (OpenTelemetry) entre Scraper ► Processor ► Notification.
- Metrics Prometheus + Grafana con *service-level objectives* (SLO 99 % disponibilidad).

Con esto se respalda el compromiso de trazabilidad y detección temprana de fallos citado por el equipo.

4.5 Resumen de impacto

Atributo de calidad	Brecha inicial	Mejora lograda	Evidencia
Disponibilidad	85 %	98 %	Prueba de estrés (JMeter)
Latencia Scraper	9,2 s	4,1 s	Métrica Prometheus
Escalabilidad	Mono-instancia	Auto-scale HPA	K8s HPA logs
Mantenibilidad	Cobertura 68 %	87 %	Reportepytest-cov

5. Discusión y Conclusiones

La propuesta arquitectónica mejora considerablemente los atributos de calidad clave definidos por los stakeholders: disponibilidad, escalabilidad, seguridad y mantenibilidad. La aplicación de la metodología ATAM logró identificar y jerarquizar escenarios claves, lo que facilitó la toma de decisiones técnicas justificadas, centradas en la resiliencia, escalabilidad y disponibilidad del sistema.

A partir de los resultados de las pruebas de estrés iniciales y las brechas, se decidió implementar una arquitectura basada en microservicios desacoplados, contenedores orquestados por Kubernetes y una comunicación asincrónica mediante RabbitMQ. Estas decisiones fueron clave para mitigar cuellos de botella detectados en el scraping y notificación, reducir la latencia del sistema y habilitar el escalado horizontal ante alta demanda.

Además, se incorporaron patrones de diseño orientados a la resiliencia como Circuit Breaker + Retry, observabilidad tales como; tracing, métricas y logs, y mantenibilidad del tipo Clean Architecture. Estos, aportan un valor técnico tangible, como la mejora de la cobertura de pruebas y la trazabilidad operacional. También se reforzaron aspectos de seguridad, aplicando control de acceso basado en roles y cifrado en tránsito, con una hoja de ruta clara para futuras extensiones en seguridad y auditoría.

Desde una perspectiva estratégica, la arquitectura To-Be no solo resuelve las deficiencias técnicas detectadas, sino que establece las bases para un sistema evolutivo, flexible y preparado para producción real. De esta manera, se logra aplicar

la transformación digital del sector legal, aportando eficiencia operativa, reducción de errores humanos y mayor capacidad de respuesta ante eventos críticos.

Para concluir, la arquitectura propuesta demuestra estar alineada con los principios fundamentales de TOGAF, permitiendo una evolución sostenible del sistema mediante una estructura modular, observable, segura y resiliente, que responde directamente a las necesidades actuales del dominio judicial y abre posibilidades reales de escalamiento e implementación en estudios jurídicos. Una solución efectiva, escalable, concreta, medible y buscando la mejora continua.