

#INFRA PLANEJAMENTO MIGRAÇÃO CKAN

1. **Motivação:**

- a. Volume elevado de recursos da equipe de infra é gasto para resolver bugs e issues na infraestrutura do CKAN atual
- b. CKAN exige que se crie muitos plugins para coisas que gostaríamos que fossem nativos.
- c. Temos uma série de desejos de features que o CKAN é engessado para permitir.
- d. Gostaríamos de ter uma estrutura de permissão mais sofisticada. A estrutura de permissão do CKAN não atende às nossas necessidades.

2. **Contra-argumento:**

- a. Mesmo após a migração, será preciso um investimento de tempo elevado para manutenção da nova infraestrutura de metadados.

3. **Features - Não negociáveis:**

- a. Pesquisa com filtros/slices/contagens (Solr/ElasticSearch)
- b. Gerenciar packages e resources (CRUD)
 - i. Create: Validação (Pydantic) / Schema para o frontend montar o form
 - ii. Update: Validação / Schema / Atualizar o search index / Patch/Put / (audit log?)
 - iii. View:
 - iv. Delete: (audit log?)
- c. Gerenciar Usuários: hoje temos basicamente só usuário normal e admin.
- d. Backup do banco e dos binários
- e. Schema para entidades fundamentais: usuários, organizações, temas, etiquetas, conjuntos, fontes originais, pedidos LAI, tabelas BD+
- f. Endpoints já existentes no website <https://basedosdados.org/openapi>
- g. Usar terraform + kubernetes
- h. Ambiente dockerizado
- i. Ambiente de teste local/cloud:
 - i. Framework de testes (conexão e mock de banco e outros serviços já pronto pro dev poder adicionar testes com pouco esforço)
- j. Documentação e Onboarding.
- k. HTTPS e renovação de certificado

4. Features - Desejáveis:

- a. Deploy: Fazer um push e o deploy acontecer magicamente.
- b. Infrastructure as a service: terraform, IAM
- c. Schema para novas entidades fundamentais: documentos, anexos, análises comunitárias ([GitHub](#))
- d. Internacionalização
- e. Desacoplar schema de metadados
 - i. Permitir que organizações personalizem seus schemas.
 - ii. Permitir que a validação de metadados não dependa do servidor da BD estar online.
- f. Potencializar espaço de usuário: fórum, seguir bases, subir dados, postar análises, conectar com serviços (GCP, AWS, Kaggle), etc.
- g. Web 2.0 - Comentários / Likes / Salvar buscas / Notificação de atualização / Badges / Quem baixou
- h. Estruturar IAM (em acordo com GCP e sistema de permissões na BD)
- i. Permitir abstração de nomes de conjuntos e tabelas materializadas em cima de tabelas usando IDs/hash como nome. [GitHub Issue #425](#)
- j. Permitir sistema de gestão de dados e metadados direto via web.
 - i. Ambiente de desenvolvimento (back-end prefect)
 - ii. Inferência de metadados
 - iii. Validação de metadados
 - iv. Data checks
- k. Estrutura para Metadata Graph
- l. Separar Front do Back (também no repositório GitHub. Hoje é mono repo `website`)

5. Stack

- a. Back-end
 - i. Django
 - ii. FastAPI
- b. Banco de dados do back-end
 - i. Postgres
- c. ORM
 - i. Sqlalchemy
 - ii. SQLmodel
 - iii. Django ORM
- d. DB migrations
 - i. Alembic
 - ii. Django ORM
- e. Search
 - i. [Postgres FTS](#)

- ii. Elastic Search
- iii. Solr

6. Plano de ação

- a. Mapear custos e benefícios de opções de stack: features, custo de migração, manutenção, comunidade, etc.
- b. Decidir stack.
- c. Mapear pontos de mudança no nosso ecossistema.
- d. Design do banco de dados (entidades, relacionamentos)
 - i. Diagrama lógico entidade/relacionamento
- e. Desenhar a interface publica do backend (endpoints/pushs?)
- f. Montar MVP em cluster paralelo.

Status prefeitura:

Usavam planilhas de arquitetura para preenchimento de metadados. Problema: ficava bagunçada com muitas pessoas diferentes fazendo. Solução foi criar uma API com Django. O maior problema inicialmente foi a criação de uma interface. Usou-se o Django Admin para lidar com isso.

Para segunda versão tentou-se criar uma interface mais amigável.

Stack:

1. API: FastAPI
2. Cache: redis (estudar como integrar com FastAPI)
(<https://developer.redis.com/develop/python/fastapi/>)
3. Postgres
4. ORM: SQLmodel
5. ElasticSearch (estudar se é a melhor opção)
6. DB migrations: Alembic

Primeiros passos:

1. Usar repositório API que já existe na Organização da BD
2. Replicar os endpoints que temos atualmente usando FastAPI (estrutura e arquitetura do repositório será criada pela equipe da prefeitura)
3. Separar FrontEnd de BackEnd
4. Criar design do banco de dados

Obs: 2 e 4 irão ocorrer em paralelo