

Acelerando a Transição Energética no Brasil: Oportunidades de Aplicação do Amazon Braket na Otimização, Previsão e Gestão de Redes Elétricas

Eduardo M. Fagundes
São Paulo, Brasil
eduardo.mayer@efagundes.com

Abstract - The expansion of the Brazilian National Interconnected System (SIN) towards a matrix dominated by variable renewable energy sources (VRES) imposes severe combinatorial challenges on grid operation, particularly in Unit Commitment (UC) and Optimal Power Flow (OPF) tasks. Classical solvers face exponential time complexity when addressing the stochastic nature of wind and solar generation alongside distributed resources. This white paper explores the application of Quantum Computing (QC) to resolve these computational bottlenecks, positioning Amazon Braket as a critical facilitator for deploying hybrid quantum-classical model. We examine the use of Quantum Annealing for optimizing load dispatch and Quantum Machine Learning (QML) for high-fidelity forecasting. By leveraging Braket's managed access to diverse Quantum Processing Units (QPUs), we demonstrate a scalable pathway to enhance grid resilience and operational efficiency without the prohibitive capital expenditure of on-premise quantum hardware.

Keywords - *Amazon Braket, Hybrid Quantum-Classical Computing, National Interconnected System (SIN), Renewable Energy Integration, Unit Commitment, Quantum Annealing.*

I. INTRODUÇÃO

A transição global para uma economia de baixo carbono impõe uma pressão sem precedentes sobre as infraestruturas de energia elétrica. No cenário brasileiro, o Sistema Interligado Nacional (SIN) destaca-se por uma matriz historicamente limpa, dominada pela geração hidrelétrica. No entanto, a recente e agressiva expansão de fontes de energia renovável variáveis (FER), especificamente eólica e solar, introduziu novos paradigmas de operação. Enquanto a diversificação aumenta a segurança energética, a natureza estocástica e intermitente destas fontes — sujeitas a variações climáticas abruptas em parques eólicos offshore e flutuações de irradiação solar — desafia os modelos tradicionais de previsão e estabilidade da rede.

À medida que o sistema evolui para um modelo mais descentralizado, caracterizado pela proliferação de Recursos Energéticos Distribuídos (DERs), microrredes e a iminente eletrificação da frota de veículos (VEs), a complexidade matemática para gerenciar o fluxo de energia cresce exponencialmente. Os operadores do sistema enfrentam gargalos computacionais críticos em tarefas fundamentais, como o Compromisso de Unidade (*Unit Commitment - UC*) e o Fluxo de Potência Ótimo (*Optimal Power Flow - OPF*). Estes são classificados como problemas de otimização combinatória NP-difíceis (*Non-deterministic Polynomial-time hard*).

Em computadores clássicos, a resolução de problemas NP-difíceis para redes de grande escala exige simplificações lineares ou heurísticas que sacrificam a precisão pela velocidade, resultando muitas vezes em soluções subótimas

que implicam em maiores custos operacionais e desperdício de energia. Com o advento de redes inteligentes multidirecionais e a necessidade de despacho em tempo quase real, a capacidade de processamento clássico aproxima-se de seu limite teórico para garantir a resiliência e a eficiência do sistema.

Neste contexto, a computação quântica (CQ) emerge não apenas como uma evolução incremental, mas como uma mudança de paradigma capaz de resolver problemas intratáveis classicamente através de fenômenos como superposição, emaranhamento e tunelamento quântico. No entanto, a barreira de entrada para a adoção desta tecnologia — que envolve custos proibitivos de hardware e a complexidade de manutenção de *qubits* em ambientes criogênicos — tem sido historicamente alta.

O Amazon Braket surge como a solução facilitadora para este ecossistema, oferecendo um serviço de computação quântica totalmente gerenciado que democratiza o acesso a Unidades de Processamento Quântico (QPUs) de última geração. A plataforma atua como um *hub* unificado, permitindo que pesquisadores e engenheiros do setor elétrico brasileiro accessem, sob demanda, diferentes paradigmas de hardware essenciais para aplicações energéticas distintas:

1. **Recozimento Quântico (*Quantum Annealing*):** Disponível através de dispositivos D-Wave, é a tecnologia mais madura para resolver problemas de otimização combinatória, como o posicionamento estratégico de medidores, reconfiguração de redes de distribuição e agendamento de carga de VEs.
2. **Computação Baseada em Portas (*Gate-Based*):** Acessível via processadores de íons aprisionados (IonQ) e supercondutores (Rigetti, OQC), fundamental para a simulação de materiais moleculares (como novos eletrólitos para baterias e catalisadores de hidrogênio) e algoritmos de Aprendizado de Máquina Quântico (QML) para previsão climática de alta fidelidade.
3. **Simulação de Átomos Neutros:** Através da QuEra, permitindo a simulação analógica de sistemas quânticos complexos, relevante para a modelagem de novos materiais energéticos.

Além do acesso ao hardware, o Amazon Braket facilita a implementação de modelos híbridos (Quântico-Clássicos). Esta abordagem é crítica na era atual de "Ruído de Escala Intermediária" (NISQ), onde a ferramenta orquestra *Jobs Híbridos* que delegam sub-rotinas quânticas complexas às QPUs enquanto mantêm o pré/pós-processamento em instâncias clássicas (EC2) de alto desempenho. Este *White Paper* explora como a aplicação estratégica do Amazon

Braket pode acelerar a modernização do setor elétrico brasileiro, transformando desafios de complexidade computacional em oportunidades de eficiência operacional e sustentabilidade.

II. AMAZON BRAKET: ARQUITETURA E CAPACIDADES PARA O SETOR DE ENERGIA

A transição da computação quântica de experimentos acadêmicos para aplicações industriais robustas exige uma infraestrutura agnóstica e escalável. Conforme destacado na apresentação técnica *AWS re:Invent 2025 - Quantum Computing with Amazon Braket: From Exploration to Enterprise (CMP411)*, o Amazon Braket fornece a camada de orquestração necessária para que empresas do setor elétrico desenvolvam, testem e operem algoritmos quânticos sem o custo proibitivo de manter hardware criogênico ou fotônico *on-premise*.

Para o Sistema Interligado Nacional (SIN) brasileiro, caracterizado por sua vastidão continental e matriz híbrida, o Braket oferece três pilares arquiteturais fundamentais: acesso diversificado a hardware, execução de trabalhos híbridos de baixa latência e simulação de alto desempenho.

A. Acesso Multi-Hardware: O Paradigma "Right Tool for the Job"

O setor de energia não enfrenta um único tipo de problema matemático; ele lida com classes distintas de complexidade. A arquitetura do Amazon Braket permite o acesso unificado via API a diferentes paradigmas de computação quântica (QPUs), permitindo que operadores de rede selecionem o backend mais adequado para cada desafio específico:

1. Reconhecimento Quântico (*Quantum Annealing*) para Otimização Combinatória: Dispositivos de reconhecimento, como os fornecidos pela D-Wave no Braket, são projetados especificamente para minimizar funções de energia em problemas de otimização combinatória. No contexto brasileiro, isso é crítico para problemas NP-difícéis como o Fluxo de Potência Ótimo (OPF) e o *Unit Commitment* (Compromisso de Unidade). A literatura indica que o reconhecimento quântico supera métodos clássicos (como *Simulated Annealing*) em velocidade e precisão para a localização de falhas em redes de distribuição e para o despacho de microrredes resilientes. O acesso a este hardware permite modelar o problema como uma Otimização Binária Quadrática Irrestrita (QUBO), essencial para lidar com a natureza discreta do despacho de geradores e manobras de rede.
2. Computação Baseada em Portas (Gate-Based) para Simulação e QML: Para problemas que exigem a manipulação de estados quânticos complexos através de emaranhamento e superposição universal, o Braket oferece acesso a máquinas baseadas em íons aprisionados (IonQ), supercondutores (Rigetti, OQC) e átomos neutros (QuEra).
 - *Simulação Química*: O desenvolvimento de novos materiais para baterias de íon-lítio

e estado sólido, bem como catalisadores para hidrogênio verde, depende da simulação precisa de hamiltonianos moleculares. Algoritmos como a Estimativa de Fase Quântica (QPE) e VQE executados nestas máquinas podem prever propriedades de eletrólitos (ex: $\$Li_3PS_4\$$) com precisão superior ao DFT clássico, acelerando a inovação em armazenamento.

- *Quantum Machine Learning (QML)*: Para a previsão de geração eólica e solar, o uso de Redes Neurais Quânticas (QNN) e QLSTM em computadores baseados em portas tem demonstrado capturar correlações não lineares em dados meteorológicos que escapam às redes clássicas, reduzindo erros de previsão (RMSE) em cenários de alta variabilidade.

B. Amazon Braket Hybrid Jobs: O Motor da Era NISQ

Na era atual de Ruído de Escala Intermediária (NISQ), os qubits são suscetíveis a erros e possuem tempo de coerência limitado. A solução pragmática para aplicações industriais reside em Algoritmos Híbridos Variacionais, onde uma CPU/GPU clássica trabalha em *loop* fechado com uma QPU.

A funcionalidade *Amazon Braket Hybrid Jobs* é crucial para o setor elétrico pois gerencia essa interação com prioridade de execução e baixa latência, eliminando a sobrecarga de filas de acesso à QPU entre iterações. Isso é vital para dois algoritmos centrais na modernização da rede:

1. QAOA (*Quantum Approximate Optimization Algorithm*): Utilizado para problemas de particionamento de rede e posicionamento estratégico de medidores e PMUs. O *Hybrid Jobs* permite que o otimizador clássico ajuste os parâmetros do circuito quântico iterativamente para encontrar a configuração de rede mais resiliente, suportando abordagens de decomposição (como Benders ou ADMM quântico) para resolver problemas maiores do que a capacidade física do chip quântico permitiria isoladamente.
2. VQE (*Variational Quantum Eigensolver*): Essencial para a descoberta de materiais. O componente clássico do *Hybrid Job* otimiza os parâmetros do *ansatz* quântico para encontrar o estado fundamental de energia de moléculas complexas de armazenamento, viabilizando o design de baterias de próxima geração.

Ao colocar recursos clássicos e quânticos, o Braket permite que concessionárias de energia executem esses algoritmos iterativos de forma eficiente, transformando problemas teóricos em soluções de engenharia aplicáveis.

C. Simuladores Gerenciados (SV1, TN1): Mitigação de Risco e Custo

Antes de submeter circuitos a hardware quântico real (que possui custo por *shot*), é imperativo validar a lógica e a

escalabilidade dos algoritmos. O Braket fornece simuladores de alto desempenho totalmente gerenciados que são ferramentas indispensáveis na fase de P&D de concessionárias:

- **SV1 (State Vector Simulator):** Ideal para validar circuitos de QML profundos usados em previsão de carga e clima. Ele permite a simulação completa da função de onda para circuitos de até 34 qubits, permitindo que cientistas de dados ajustem hiperparâmetros de QNNs e LSTMs quânticos em um ambiente sem ruído antes do *deploy*.
- **TN1 (Tensor Network Simulator):** Projeto para circuitos com emaranhamento estruturado, o TN1 é particularmente relevante para simular a topologia de redes elétricas complexas representadas por grafos. Ele permite testar algoritmos de otimização de grafos em escalas maiores (até 50 qubits para certas topologias), ajudando a validar modelos de detecção de falhas e reconfiguração de rede antes de aplicá-los em cenários reais.

Essa arquitetura de simulação reduz drasticamente o risco financeiro e técnico, permitindo que o setor elétrico brasileiro "falhe rápido e aprenda rápido" (*fail fast, learn fast*) na implementação de soluções quânticas.

III. OTIMIZAÇÃO OPERACIONAL E DESPACHO DE CARGA

A operação do Sistema Interligado Nacional (SIN) envolve a resolução contínua de problemas de otimização combinatória, cuja complexidade aumenta não linearmente com a introdução de fontes intermitentes e recursos energéticos distribuídos. Nesta seção, exploramos como o Amazon Braket facilita o acesso a *Annealers Quânticos* (especificamente dispositivos D-Wave) para resolver problemas NP-difíceis que desafiam os *solvers* clássicos atuais.

A. Unit Commitment e Despacho Econômico via QUBO

O problema de *Unit Commitment* (UC) — determinar quais geradores ligar ou desligar e quando — é central para o despacho econômico, especialmente ao equilibrar a "curva de pato" gerada pela energia solar e a volatilidade eólica.

No paradigma de *Quantum Annealing* (QA), este problema é mapeado para um modelo de Otimização Binária Quadrática Irrestrita (QUBO). A função objetivo busca minimizar o custo total de operação (combustível, partida, penalidades ambientais) sujeito a restrições operacionais (rampas de subida/descida, tempos mínimos de operação).

- **Desafio de Implementação:** A codificação de restrições de desigualdade (ex: limites de geração $\$P_{\{min\}} \leq P \leq P_{\{max\}}$) em computadores quânticos tradicionalmente exige o uso de "variáveis de folga" (*slack variables*), que consomem *qubits* preciosos e limitam o tamanho do problema que pode ser resolvido no hardware atual.
- **Solução via Braket:** Pesquisas recentes acessíveis via *backends* D-Wave demonstram a eficácia da

técnica de "Penalização Desbalanceada" (*Unbalanced Penalization*). Este método elimina a necessidade de variáveis de folga para certas restrições, codificando-as diretamente na função de energia do Hamiltoniano. Resultados indicam que esta abordagem permite resolver instâncias de agendamento de unidades com menos *qubits* e maior eficiência do que formulações tradicionais, viabilizando testes em redes maiores.

- **Escalabilidade Híbrida:** Para redes de grande escala, o Amazon Braket permite orquestrar abordagens de decomposição distribuída, como o ADMM Quântico (*Alternating Direction Method of Multipliers*). Neste modelo, o problema global de despacho é decomposto: o computador quântico resolve os subproblemas combinatórios complexos (UC discreto) explorando superposição e emaranhamento, enquanto instâncias clássicas (Amazon EC2) coordenam as variáveis contínuas e os multiplicadores de Lagrange, convergindo para soluções viáveis mais rapidamente que métodos puramente clássicos.

B. Gestão de Microrredes e Resiliência

A resiliência da rede contra eventos extremos (tempestades severas, falhas em cascata) depende da capacidade de seccionar a rede em microrredes autossustentáveis (*islanding*) e restaurar cargas críticas rapidamente.

- **Restauração de Serviço:** O uso de *Quantum Annealing* para a formação de microrredes demonstrou superioridade na restauração de sistemas de distribuição. Utilizando o *solver* híbrido *Constrained Quadratic Model* (CQM) da D-Wave (acessível via Braket), é possível otimizar a topologia da rede e o chaveamento de linhas para maximizar a carga restaurada. Estudos no sistema IEEE 240-barras mostram que esta abordagem supera *solvers* clássicos (como Gurobi) em tempo de execução e qualidade da solução em cenários de alta complexidade combinatória.
- **Logística de Hidrogênio e Armazenamento Móvel:** No contexto brasileiro, onde o hidrogênio verde (H2V) ganha força, a logística de distribuição torna-se crítica. Algoritmos de Decomposição de Benders Combinatória Assistida por Quantum foram aplicados para otimizar a sinergia entre sistemas de distribuição de energia e unidades móveis de armazenamento de hidrogênio (caminhões-tanque ou baterias móveis). O componente mestre do problema (roteamento e agendamento discreto das unidades móveis) é resolvido eficientemente como um QUBO no *annealer*, enquanto o subproblema de fluxo de potência é tratado classicamente, garantindo o suprimento em áreas isoladas ou congestionadas.

C. Localização de Falhas em Redes de Distribuição

A identificação rápida e precisa de seções defeituosas é vital para os indicadores de continuidade (DEC/FEC). Métodos

clássicos baseados em matrizes de impedância ou algoritmos genéticos podem ficar presos em ótimos locais ou exigir tempo excessivo de convergência em redes radiais complexas com Geração Distribuída (GD).

- Vantagem do Tunelamento Quântico: Algoritmos de reconhecimento quântico (QA) exploram o efeito de tunelamento (*quantum tunneling*) para atravessar barreiras de energia na paisagem de otimização, escapando de mínimos locais com mais facilidade que o reconhecimento simulado térmico.
 - Resultados: A aplicação de um Algoritmo de Reconhecimento Quântico Aprimorado (IQA) para localização de falhas demonstrou 100% de precisão na identificação de seções defeituosas em redes de teste (IEEE 33-nós), mesmo na presença de distorção de sinais de informação. O método exigiu significativamente menos iterações para convergir em comparação com algoritmos evolutivos clássicos, sugerindo um caminho promissor para automação de centros de operação de distribuição (COD)
- no Brasil.

IV. PREVISÃO DE GERAÇÃO RENOVÁVEL COM QML

Enquanto o *Quantum Annealing* (discutido na Seção III) domina a otimização combinatória, a previsão de geração renovável exige uma abordagem diferente: a modelagem de séries temporais estocásticas e altamente não lineares. Para esta tarefa, o Amazon Braket fornece acesso a computadores quânticos baseados em portas (*Gate-Based*), como IonQ (íons aprisionados), Rigetti e OQC (supercondutores), além de integração nativa com a biblioteca *open-source* PennyLane.

Esta seção detalha como o Aprendizado de Máquina Quântico (QML) supera as limitações das redes neurais clássicas na captura de dinâmicas caóticas atmosféricas.

A. Previsão Eólica e Solar: QNNs e QLSTMs

A variabilidade climática no Nordeste brasileiro, região que concentra a maior parte da geração eólica e solar do país, impõe desafios severos ao *nowcasting* (previsão de curtíssimo prazo). Redes neurais clássicas (como LSTMs e CNNs) muitas vezes falham em capturar mudanças abruptas na velocidade do vento ou na irradiação devido à "explosão de gradientes" e à incapacidade de modelar correlações de alta ordem em espaços de dados limitados.

1. Arquitetura Híbrida via PennyLane no Braket: Utilizando a integração do Amazon Braket com o PennyLane, desenvolvedores podem criar Redes Neurais Quânticas (QNN) que funcionam como extratores de características (*feature extractors*) avançados.
 - *Mecanismo:* A camada quântica mapeia os dados de entrada clássicos (velocidade do vento, temperatura, pressão) para um espaço de Hilbert de alta dimensão. Neste espaço, correlações não lineares complexas

tornam-se linearmente separáveis, algo computacionalmente inviável para *kernels* clássicos. Os dados processados são então alimentados em uma rede clássica para a regressão final.

- *Aplicação Prática:* Um estudo recente aplicado a dados meteorológicos da Bahia demonstrou que um modelo QNN híbrido compete favoravelmente com o *Multilayer Perceptron* (MLP) clássico para previsões de velocidade do vento de até seis horas à frente, demonstrando maior robustez em cenários de generalização.
- 2. Quantum LSTM (QLSTM) para Séries Temporais: Para a energia solar fotovoltaica, a arquitetura QLSTM (*Quantum Long Short-Term Memory*) substitui as camadas lineares internas de uma LSTM clássica por circuitos quânticos variacionais (VQC).
 - *Vantagem:* Testes comparativos indicam que modelos QLSTM podem reduzir o Erro Médio Absoluto (MAE) e o Erro Quadrático Médio (RMSE) em mais de 40% comparados aos *baselines* clássicos, utilizando significativamente menos parâmetros treináveis.
 - *Eficiência de Dados:* O QLSTM demonstrou convergência mais rápida e precisão superior especificamente em cenários onde os dados históricos são limitados ou ruidosos, uma situação comum em novos parques solares no Brasil.
 - *Implementação no Braket:* O treinamento destas redes é intensivo. O uso do simulador vetorial SV1 do Amazon Braket permite a paralelização massiva de circuitos durante a fase de treinamento (cálculo de gradientes), reservando o hardware quântico real (ex: IonQ Aria) para inferência ou validação final.

B. Estabilidade da Rede: Classificadores Variacionais Quânticos (VQC)

Além de prever a geração, é crucial antecipar o impacto dessa geração na estabilidade da frequência e tensão do SIN. A inércia reduzida de fontes baseadas em inversores torna a rede suscetível a instabilidades rápidas.

- Classificação de Estados em Tempo Real: O uso de Classificadores Variacionais Quânticos (VQC) permite categorizar o estado da rede (ex: "Estável" vs. "Instável") com base em leituras de PMUs (*Phasor Measurement Units*).
- Resultados: Experimentos em redes de teste de 4 nós demonstram que VQCs conseguem distinguir padrões sutis de instabilidade que antecedem falhas, superando classificadores clássicos como SVM (*Support Vector Machines*) em precisão, especialmente à medida que a dimensionalidade dos dados do sensor aumenta.

- Pipeline no Braket: Um *pipeline* típico envolve a ingestão de dados via Amazon Kinesis, pré-processamento clássico e classificação via circuito VQC executado em um simulador de baixa latência ou QPU no Braket, fornecendo alertas aos operadores do sistema.

V. DESCOBERTA DE MATERIAIS PARA ARMAZENAMENTO

O desenvolvimento de tecnologias de armazenamento de energia de próxima geração é um gargalo crítico para a transição energética. A simulação de novos materiais em computadores clássicos enfrenta a "maldição da dimensionalidade", pois a complexidade de calcular a função de onda de sistemas moleculares fortemente correlacionados escala exponencialmente com o número de elétrons. O Amazon Braket habilita a superação desta barreira através da Simulação Hamiltoniana, permitindo que centros de pesquisa brasileiros utilizem algoritmos variacionais para reduzir drasticamente o tempo e o custo de P&D em baterias e hidrogênio verde.

A. Baterias de Estado Sólido e o Algoritmo VQE

A segurança e a densidade energética das baterias de íon-lítio atuais são limitadas pelos eletrólitos líquidos inflamáveis. A transição para eletrólitos de estado sólido (SSEs) é uma prioridade global, mas a descoberta de materiais com condutividade iônica adequada é complexa. Para enfrentar este desafio, utiliza-se o *Variational Quantum Eigensolver* (VQE), um algoritmo híbrido quântico-clássico ideal para a era NISQ (*Noisy Intermediate-Scale Quantum*).

1. Simulação de Li_3PS_4 no Braket: Estudos recentes demonstraram a aplicação do VQE para calcular a energia do estado fundamental (*Ground-State Energy*) do Tiofosfato de Lítio (Li_3PS_4), um candidato promissor para eletrólitos sólidos.
 - *Vantagem Quântica:* Ao contrário dos métodos clássicos como *Density Functional Theory* (DFT) ou *Hartree-Fock*, que muitas vezes falham em capturar correlações eletrônicas complexas em materiais de transição, a simulação quântica via VQE consegue modelar a estrutura eletrônica e a dinâmica de reações eletroquímicas com precisão superior.
 - *Execução Híbrida:* No Amazon Braket, o VQE é executado via *Hybrid Jobs*. A QPU (como a IonQ Aria ou Rigetti) prepara o *ansatz* (estado de teste) e mede a expectativa do Hamiltoniano, enquanto a CPU clássica (EC2) otimiza os parâmetros variacionais em um *loop* fechado. Isso permite investigar propriedades de transporte de íons e estabilidade térmica do Li_3PS_4 sem a necessidade inicial de síntese em laboratório molhado, acelerando o ciclo de descoberta.

2. Espectroscopia de Perda de Energia (EELS): Além da energia estática, algoritmos quânticos estão sendo desenvolvidos para simular espectros EELS em materiais catódicos como o Li_2MnO_3 . Isso permite aos pesquisadores entenderem os mecanismos de degradação e redox de oxigênio em nível atômico, essenciais para estender a vida útil das baterias.

B. Hidrogênio Verde e Nanocatalisadores

O Brasil possui um potencial estratégico para liderar o mercado de Hidrogênio Verde (H2V). No entanto, a eletrolise da água ainda depende de catalisadores caros baseados em metais do grupo da platina. A redução de custos exige a descoberta de novas ligas catalíticas eficientes.

1. Design Racional via QML e DFT: A integração de *Quantum Machine Learning* (QML) com cálculos DFT tem se mostrado revolucionária para o design de nanocatalisadores multicomponentes. Algoritmos quânticos podem processar características complexas — como o centro da banda-d, energia de coesão e energia de adsorção de hidrogênio — de milhares de ligas candidatas.
 - *Resultados Promissores:* Modelos QML demonstraram uma precisão preditiva 17% superior aos modelos de ML clássicos na triagem de materiais. O uso dessa abordagem identificou catalisadores trimetálicos, como Pt-Ni-Mo e Pd-Cu-Co, que apresentam baixa energia livre de adsorção de hidrogênio (otimizando a reação) e alta estabilidade térmica (até 800 K).
 - *Impacto Econômico:* A simulação destes materiais no Braket permite prever uma redução de sobrepotencial de 25-30% em comparação aos catalisadores convencionais. Para o cenário brasileiro, isso significa a possibilidade de desenvolver tecnologia nacional para eletrolisadores mais baratos, aproveitando a infraestrutura de nuvem da AWS para evitar o alto CAPEX de supercomputadores dedicados.
2. Fotocatálise Binária: Além da eletrolise, o Braket suporta pesquisas em fotocatálise (quebra da água usando luz solar). A combinação de DFT com IA quântica acelera a otimização de *band gaps* em materiais como TiO_2 e $\text{g-C}_3\text{N}_4$, facilitando o design de heterojunções que maximizam a absorção de luz solar para produção direta de hidrogênio.

VI. INTEGRAÇÃO COM IA GENERATIVA E RAG (RETRIEVAL-AUGMENTED GENERATION)

Enquanto a otimização e a previsão (discutidas nas seções anteriores) lidam com dados estruturados, a operação do setor elétrico brasileiro enfrenta um desafio paralelo de dados *não estruturados*. A conformidade com normas da ANEEL, os

Procedimentos de Rede do Operador Nacional do Sistema (ONS) e milhares de manuais de equipamentos legados criam um vasto repositório de conhecimento que é difícil de consultar em tempo real.

Nesta seção, propomos a implementação de sistemas de Geração Aumentada por Recuperação (RAG) para criar assistentes cognitivos para operadores de rede, e discutimos como a computação quântica pode, no futuro, otimizar a etapa crítica de recuperação de informação.

A. O Desafio da Documentação e a Alucinação

Modelos de Linguagem Grande (LLMs) tradicionais, como o GPT-4, sofrem de duas limitações críticas para o setor de energia: conhecimento desatualizado (baseado apenas no treino prévio) e alucinações (geração de fatos incorretos com alta confiança). No contexto de uma sala de controle do SIN (Sistema Interligado Nacional), uma alucinação sobre um procedimento de manobra é inaceitável. Além disso, a regulação muda frequentemente, tornando o re-treinamento constante de modelos (*Fine-tuning*) caro e impraticável.

B. Solução Proposta: Arquitetura RAG na AWS

A arquitetura RAG supera essas limitações ao conectar o LLM a uma base de conhecimento externa dinâmica. O processo ocorre em quatro etapas: Indexação, Recuperação, Aumento e Geração.

1. Arquitetura de Referência: Utilizando a infraestrutura da AWS, a solução proposta integra o Amazon Bedrock (para acesso a LLMs fundamentais) com o Amazon Kendra ou OpenSearch (para indexação vetorial e busca semântica).
 - *Ingestão de Dados:* Documentos técnicos (PDFs de manuais, normas do ONS) são processados e divididos em fragmentos (*chunks*). Metadados críticos, como "data de revisão" ou "tipo de equipamento", são anexados para filtragem precisa.
 - *Busca Híbrida:* O sistema utiliza busca vetorial (embeddings densos para capturar semântica) combinada com busca por palavras-chave (BM25) para garantir que termos técnicos específicos do setor elétrico sejam recuperados corretamente.
2. Aplicação Prática (Cenário de Operação): Considere um operador diante de uma falha na "Substation X". Ele consulta o sistema: "*Quais os procedimentos de recomposição para a subestação X?*".
3. *Recuperação:* O sistema busca no banco vetorial os fragmentos mais relevantes dos manuais técnicos e procedimentos de rede vigentes.
4. *Geração Fundamentada:* O LLM recebe a pergunta *mais* o contexto recuperado e gera a resposta, citando explicitamente as fontes (ex: "*Conforme Procedimento ONS 2.3, item 4...*"). Isso permite a verificação humana e mitigação de riscos.

C. Otimização de RAG via Computação Quântica (Q-NLP)

Embora o RAG clássico seja robusto, ele enfrenta "Pontos de Falha" conhecidos, como a recuperação de documentos irrelevantes (FP2) ou a perda de contexto em documentos longos (FP3). À medida que a base de conhecimento do setor elétrico escala para Petabytes, a busca vetorial clássica (KNN/ANN) pode se tornar imprecisa ou lenta.

O Amazon Braket habilita a pesquisa em Processamento de Linguagem Natural Quântico (Q-NLP) para otimizar a etapa de recuperação:

1. Indexação Semântica Quântica: Algoritmos quânticos podem mapear palavras e frases em espaços de Hilbert de dimensão exponencialmente maior que os espaços vetoriais clássicos. Isso permite capturar nuances semânticas sutis (como a diferença entre "falha na linha" e "falha no barramento") que *embeddings* clássicos podem confundir. O uso de *Quantum Machine Learning* (QML) pode refinar a qualidade dos *embeddings*, melhorando a precisão contextual.
2. Otimização de Ranking (*Q-Ranking*): O problema de selecionar o conjunto ótimo de documentos para compor o contexto do LLM (dentro do limite de tokens) é, em essência, um problema de otimização combinatória (*Knapsack Problem*). Dispositivos de Recozimento Quântico (D-Wave via Braket) podem ser utilizados para resolver essa otimização em tempo real, selecionando a combinação de fragmentos que maximiza a cobertura informacional e minimiza a redundância, superando algoritmos de *re-ranking* clássicos.

Esta abordagem híbrida — RAG operando na nuvem clássica AWS, com sub-rotinas de indexação e ranking otimizadas via Braket — representa a fronteira da gestão de conhecimento para infraestruturas críticas.

VII. DESAFIOS DE IMPLEMENTAÇÃO E SEGURANÇA

A modernização do Sistema Interligado Nacional (SIN) através da computação quântica não ocorre no vácuo. À medida que as redes elétricas evoluem para Sistemas Ciber-Físicos (CPS) altamente conectados, a introdução de capacidades quânticas traz consigo tanto ferramentas de otimização quanto vetores de ameaça existenciais. Para que a adoção do Amazon Braket seja bem-sucedida no setor elétrico brasileiro, é imperativo abordar a cibersegurança pós-quântica e a realidade da infraestrutura híbrida.

A. Cibersegurança Pós-Quântica na Rede Inteligente

A segurança das *Smart Grids* depende fundamentalmente de protocolos de criptografia de chave pública (como RSA e ECC) para proteger a integridade dos dados de telemedição e os comandos de telecontrole enviados aos dispositivos de campo (IEDs, relégiadores). A emergência de computadores quânticos tolerantes a falhas ameaça quebrar esses algoritmos matemáticos, expondo a infraestrutura crítica a ataques devastadores.

1. A Ameaça "*Store-Now-Decrypt-Later*" (SNDL): Um risco imediato para as concessionárias de energia é o ataque do tipo "Armazenar agora, decifrar depois". Atores mal-intencionados podem interceptar e armazenar tráfego criptografado sensível (como segredos industriais, plantas de infraestrutura nuclear ou chaves de acesso SCADA) hoje, esperando o momento em que um computador quântico suficientemente potente esteja disponível para decifrá-lo. Dado que equipamentos do setor elétrico possuem ciclos de vida operacionais de décadas (20 a 40 anos), dados transmitidos hoje devem permanecer seguros muito além da chegada da supremacia quântica.
2. Transição para Criptografia Pós-Quântica (PQC): É mandatório que o Operador Nacional do Sistema (ONS) e as empresas de energia iniciem a avaliação de risco quântico e a migração para Criptografia Pós-Quântica (PQC). O uso de ferramentas de simulação no Amazon Braket pode auxiliar não apenas no ataque (testes de penetração), mas na validação de novos algoritmos de rede resistentes a quantum, garantindo que a modernização da rede não comprometa a segurança nacional.

B. O Modelo Híbrido como Padrão Operacional

Apesar do entusiasmo, é consenso técnico que dispositivos puramente quânticos não substituirão os computadores clássicos, mas atuarão como coprocessadores especializados. No curto e médio prazo (era NISQ), a supremacia não virá de usar *apenas* a QPU, mas de orquestrar a sinergia entre CPUs/GPUs e QPUs.

1. Necessidade de Escalabilidade Híbrida: Algoritmos puramente quânticos, como o Recozimento Quântico direto, enfrentam limitações de tamanho físico (número de *qubits* e conectividade) ao tentar resolver problemas de escala continental como o despacho do SIN. A literatura demonstra que abordagens híbridas — onde o problema é decomposto e apenas o núcleo combinatório "difícil" é enviado à QPU — superam consistentemente os métodos puramente clássicos ou puramente quânticos em termos de qualidade da solução e escalabilidade.
2. O Papel do Amazon Braket Hybrid Jobs: Para viabilizar essa arquitetura no Brasil, o recurso Amazon Braket Hybrid Jobs é essencial. Ele permite que algoritmos iterativos (como QAOA para otimização de rede ou VQE para química de baterias) executem o *loop* de otimização clássica (em instâncias EC2) e a avaliação da função de custo quântica (na QPU) com latência mínima e gestão de prioridade.
 - *Decomposição e Coordenação:* Técnicas avançadas, como a Decomposição de Benders Combinatória Assistida por Quantum ou o ADMM Quântico, dependem dessa infraestrutura híbrida para coordenar subproblemas resolvidos em

paralelo por *qubits* e processadores clássicos, permitindo otimizar redes com milhares de barras, algo inviável em hardware quântico isolado atualmente.

Portanto, a estratégia para o setor elétrico brasileiro não deve ser "esperar pelo computador quântico perfeito", mas sim integrar hoje os solucionadores híbridos disponíveis no Braket aos fluxos de trabalho de Operação (OT) e Tecnologia da Informação (IT) existentes.

VIII. CONCLUSÃO

A modernização do setor elétrico brasileiro, impulsionada pela descentralização da geração e pela penetração massiva de fontes renováveis variáveis, exige uma capacidade computacional que excede os limites dos sistemas clássicos atuais. A análise apresentada neste documento demonstra que a computação quântica não é mais uma promessa futurista distante, mas uma ferramenta emergente pronta para exploração industrial através de serviços gerenciados como o Amazon Braket.

A plataforma da AWS atua como um catalisador decisivo ao remover as barreiras de entrada de capital (CAPEX) para hardware quântico. Ao oferecer acesso unificado a *Annealers* (D-Wave) e computadores baseados em portas (IonQ, Rigetti, OQC), o Braket permite que concessionárias e o Operador Nacional do Sistema (ONS) transitem da teoria para Provas de Conceito (PoCs) tangíveis em dois frontes críticos:

1. Otimização Combinatória: A aplicação de recozimento quântico para problemas de *Unit Commitment* e reconfiguração de redes demonstrou, em estudos simulados, a capacidade de superar heurísticas clássicas em velocidade e qualidade da solução, vital para a estabilidade de microrredes e despacho econômico.
2. Inteligência Computacional Híbrida: A utilização de Redes Neurais Quânticas (QNN) e algoritmos variacionais (VQE/QAOA) via *Hybrid Jobs* oferece um novo horizonte para a previsão climática de alta fidelidade e a descoberta de materiais para armazenamento de energia, reduzindo incertezas operacionais e custos de P&D.

Além disso, a integração proposta de sistemas RAG (*Retrieval-Augmented Generation*) com a infraestrutura de dados do setor elétrico representa um salto qualitativo na gestão do conhecimento. Ao fundamentar a IA generativa em normas técnicas e procedimentos operacionais atualizados, mitiga-se o risco de alucinações, fornecendo aos operadores ferramentas de suporte à decisão confiáveis e auditáveis.

Chamada para Ação Estratégica O cenário de "vantagem quântica" será atingido gradualmente através de modelos híbridos. Portanto, recomenda-se às lideranças do setor elétrico brasileiro:

- Investimento em P&D Aplicado: Iniciar projetos pilotos focados em gargalos específicos (ex: otimização de perdas em redes de distribuição ou *nowcasting* eólico no Nordeste) utilizando os

- simuladores do Braket (SV1/TN1) para validação de algoritmos antes da execução em QPU.
- Formação de Força de Trabalho: Existe uma lacuna urgente de competências. É imperativo fomentar parcerias com universidades e utilizar o ecossistema educacional da AWS para capacitar engenheiros em linguagens de programação quântica (como PennyLane e Braket SDK), preparando uma geração de profissionais "quantum-ready".
- Preparação para Cibersegurança: Avaliar a criptografia pós-quântica (PQC) como parte da estratégia de longo prazo para proteger a infraestrutura crítica do SIN contra ameaças futuras.

Em suma, o Amazon Braket oferece a ponte necessária para que o Brasil não seja apenas um consumidor, mas um protagonista na aplicação da computação quântica para uma rede elétrica mais eficiente, resiliente e sustentável.

IX. REFERÊNCIAS

AMAZON WEB SERVICES. AWS re:Invent 2025 - Quantum Computing with Amazon Braket: From Exploration to Enterprise (CMP411). 2025. 1 vídeo. Publicado pelo canal AWS Events. Disponível em: <https://www.youtube.com/watch?v=xqb5i8RxmWE>. Acesso em: 07 dez. 2025.

BARNETT, S. et al. Seven failure points when engineering a retrieval augmented generation system. In: INTERNATIONAL CONFERENCE ON AI ENGINEERING — SOFTWARE ENGINEERING FOR AI, 3., 2024, Lisboa. Proceedings... Lisboa: [s.n.], 2024.

BASERI, Y. et al. Cybersecurity in the quantum era: assessing the impact of quantum computing on infrastructure. arXiv preprint arXiv:2404.10659, 2024.

BELCIC, I.; STRYKER, C. RAG vs. fine-tuning. IBM Think, 2024. Disponível em: <https://www.ibm.com/think/topics/rag-vs-fine-tuning>. Acesso em: 07 dez. 2025.

BI, Z. et al. Quantum annealing algorithm for fault section location in distribution networks. Applied Soft Computing, v. 149, p. 110973, 2023.

GOOGLE CLOUD. What is Retrieval-Augmented Generation (RAG)? [S.d.]. Disponível em: <https://cloud.google.com/use-cases/retrieval-augmented-generation>. Acesso em: 07 dez. 2025.

GUPTA, S.; RANJAN, R.; SINGH, S. N. A comprehensive survey of retrieval-augmented generation (RAG): evolution, current landscape and future directions. arXiv preprint, 2024.

HALAK, B. et al. A security assessment tool for quantum threat analysis. arXiv preprint arXiv:2407.13523, 2024.

HANGUN, B. et al. Quantum computing approach to smart grid stability forecasting. In: INTERNATIONAL CONFERENCE ON SMART GRID (icSmartGrid), 12., 2024. Proceedings... [S.l.]: IEEE, 2024. p. 840-843.

KHAN, S. Z. et al. Quantum long short-term memory (QLSTM) vs. classical LSTM in time series forecasting: a comparative study in solar power forecasting. Frontiers in Physics, v. 12, 1439180, 2024.

KUNITSA, A. et al. Quantum simulation of electron energy loss spectroscopy for battery materials. arXiv preprint arXiv:2508.15935, 2025.

LI, M. et al. Quantum assisted combinatorial benders' algorithm for the synergy of hydrogen and power distribution systems with mobile storage. IEEE Transactions on Power Systems, v. 40, n. 5, p. 3967-3978, 2025.

MORSTYN, T. Annealing-based quantum computing for combinatorial optimal power flow. IEEE Transactions on Smart Grid, v. 14, n. 2, p. 1093-1102, 2023.

MÜLLER, S.; DUKALSKI, M.; PHILLIPSON, F. Quantum annealing for optimizing unit scheduling in renewable energy systems: formulation and evaluation. IEEE Transactions on Power Systems, 2025.

NIKMEHR, N. et al. Quantum annealing-infused microgrids formation: distribution system restoration and resilience enhancement. IEEE Transactions on Power Systems, v. 40, n. 1, p. 463-475, 2025.

PIRES, O. M. et al. A quantum neural network model for short term wind speed forecasting using weather data. Energy and AI, v. 21, p. 100588, 2025.

POOSPADI, D. et al. Quantum machine learning for designing multi-component nanocatalysts in hydrogen production. Oxidation Communications, v. 48, n. 3, p. 849, 2025.

REDDY, O. Y. et al. Quantum computing for enhanced material discovery and optimization in electric vehicle batteries. In: IEEE NORTH-EAST INDIA INTERNATIONAL ENERGY CONVERSION CONFERENCE AND EXHIBITION (NE-IECCE), 2025. Proceedings... [S.l.]: IEEE, 2025. p. 1-5.

SAGINGALIEVA, A. et al. Photovoltaic power forecasting using quantum machine learning. Solar Energy, v. 302, p. 114016, 2025.

X. GLOSSÁRIO

Alucinação (Hallucination) Um fenômeno onde um modelo de Inteligência Artificial (LLM) gera uma resposta que é gramaticalmente correta e parece plausível, mas é factualmente incorreta ou inventada. Isso ocorre porque o modelo tenta prever a próxima palavra com base em estatísticas, sem verificar a veracidade. Em sistemas críticos como a operação de redes elétricas, alucinações podem levar a erros de segurança. O uso de RAG ajuda a reduzir esse problema ao forçar a IA a basear sua resposta em documentos reais recuperados.

Amazon Braket Um serviço de computação quântica totalmente gerenciado oferecido pela AWS. Ele funciona como um portal que permite a pesquisadores e empresas acessarem diferentes tipos de hardware quântico (como os da

D-Wave, IonQ e Rigetti) através da nuvem. É a plataforma utilizada para testar algoritmos híbridos de otimização e simulação sem a necessidade de a empresa possuir um computador quântico físico próprio, facilitando a exploração de soluções para o setor de energia.

Annealing Quântico (Quantum Annealing) Uma técnica de computação quântica especializada em resolver problemas de otimização combinatória, como encontrar a configuração mais eficiente para uma rede elétrica. Diferente dos computadores clássicos que testam soluções sequencialmente, o Annealing usa flutuações quânticas para explorar vastos espaços de soluções e encontrar o estado de "mínima energia" (a melhor solução), sendo particularmente útil para localização de falhas e despacho de energia.

Answer Relevancy (Relevância da Resposta) Uma métrica utilizada para avaliar sistemas RAG. Ela mede se a resposta gerada pela Inteligência Artificial é concisa e diretamente relacionada à pergunta feita pelo usuário, sem incluir informações desnecessárias ou divagações. É fundamental para garantir que operadores de rede recebam informações diretas e acionáveis.

Chunking (Fragmentação) O processo de dividir documentos longos (como manuais técnicos ou normas do ONS) em pedaços menores e gerenciáveis antes de armazená-los no banco de dados do sistema RAG. Uma estratégia de chunking bem-feita é crucial: pedaços muito pequenos perdem o contexto, enquanto pedaços muito grandes podem confundir a IA com informações irrelevantes. O método recursivo é frequentemente usado para respeitar a estrutura natural do texto.

Contextual Precision (Precisão Contextual) Uma métrica de avaliação para o componente de recuperação (retriever) de um sistema RAG. Ela avalia se os documentos mais relevantes para responder à pergunta aparecem no topo da lista de resultados recuperados. Uma alta precisão contextual garante que a IA receba as informações mais importantes primeiro, melhorando a qualidade da resposta final.

Contextual Recall (Revocação Contextual) Métrica que verifica se o sistema de busca conseguiu recuperar todas as informações necessárias para responder à pergunta. Ela mede a proporção de sentenças na resposta ideal que podem ser atribuídas aos documentos recuperados. Se o recall for baixo, significa que a IA não teve acesso a toda a informação necessária para formular uma resposta completa.

Criptografia Pós-Quântica (PQC) Novos métodos criptográficos projetados para serem seguros contra-ataques de computadores quânticos futuros. Como os computadores quânticos têm o potencial de quebrar a criptografia atual usada em transações digitais e controle de redes, a PQC é essencial para proteger infraestruturas críticas contra ameaças de longo prazo.

DAG (Deep Acyclic Graph) Uma estrutura de métrica utilizada para avaliar IAs, onde a decisão de qualidade segue um fluxo lógico como uma árvore de decisão. Em vez de dar uma nota arbitrária, o sistema verifica critérios específicos passo a passo (ex: "O formato está correto?" -> "Sim" -> "Os

dados estão atualizados?"). Isso torna a avaliação de saídas complexas mais determinística e confiável.

Despacho Econômico (Economic Dispatch) O processo de decidir quanto cada usina de energia deve gerar para atender à demanda total pelo menor custo possível, respeitando os limites operacionais. Algoritmos quânticos estão sendo aplicados para otimizar esse processo, lidando melhor com a complexidade introduzida por fontes renováveis intermitentes e múltiplas variáveis.

Embeddings Representações numéricas de textos, imagens ou áudios em forma de vetores (listas de números). Os embeddings capturam o significado semântico das palavras. Por exemplo, em um espaço vetorial, as palavras "falha" e "erro" estariam matematicamente próximas. Isso permite que o sistema RAG encontre documentos relevantes pelo significado, e não apenas por palavras-chave exatas.

Faithfulness (Fidelidade) Uma métrica crítica para sistemas RAG que mede se a resposta gerada pela IA é factualmente consistente com os documentos recuperados. Um sistema "fiel" não inventa informações (alucinações) e se restringe apenas ao que está nos manuais ou dados fornecidos, o que é essencial para aplicações de segurança e engenharia.

Fine-Tuning (Ajuste Fino) O processo de retreinar um modelo de IA pré-existente com um conjunto de dados específico para especializá-lo em uma tarefa ou domínio. Diferente do RAG, que consulta dados externos, o fine-tuning altera o "cérebro" do modelo. É útil para ensinar novos padrões de linguagem, mas menos eficiente para manter o conhecimento atualizado em tempo real, pois exige retreinamento constante.

G-Eval Um método moderno de avaliação de IA que utiliza um modelo de linguagem grande (como o GPT-4) para atuar como "juiz" do desempenho de outro modelo. O G-Eval usa uma série de passos de raciocínio (Chain of Thought) para dar notas baseadas em critérios subjetivos, como "coerência" ou "utilidade", alinhando-se melhor com o julgamento humano do que métricas estatísticas antigas.

Grounding (Fundamentação) O processo de vincular as respostas geradas pela IA a fontes de dados verificáveis e reais. No contexto do RAG, o grounding garante que cada afirmação feita pelo modelo possa ser rastreada até um documento específico recuperado, reduzindo alucinações e aumentando a confiança do usuário na resposta.

Hamiltoniano Na física e computação quântica, é uma função que representa a energia total de um sistema. Para resolver problemas da rede elétrica (como localização de falhas) com computadores quânticos, o problema é "traduzido" para um Hamiltoniano. O computador quântico então busca o estado de menor energia desse Hamiltoniano, que corresponde à solução ótima do problema real.

Hybrid Search (Busca Híbrida) Uma técnica de recuperação que combina a busca tradicional por palavras-chave (como o BM25) com a busca semântica vetorial (embeddings). Isso permite aproveitar o melhor dos dois mundos: a precisão de encontrar termos exatos (como

códigos de erro específicos) e a capacidade de entender o contexto e a intenção da pergunta.

LLM (Large Language Model) Modelos de inteligência artificial treinados em vastas quantidades de texto que conseguem entender e gerar linguagem humana. Exemplos incluem GPT-4, Claude e Llama. Eles são o "motor" gerativo dentro de um sistema RAG, responsáveis por sintetizar a resposta final baseada nos dados recuperados.

LLM-as-a-judge (LLM como Juiz) Uma abordagem de avaliação onde um LLM avançado é usado para analisar e dar notas às respostas geradas por outro sistema de IA. É considerado um dos métodos mais confiáveis para avaliar nuances linguísticas e semânticas que métricas matemáticas simples não conseguem captar.

Nowcasting Previsão meteorológica de curtíssimo prazo (geralmente de 0 a 6 horas). É crucial para a operação de energias renováveis, permitindo antecipar mudanças repentinas na geração solar ou eólica devido a nuvens ou rajadas de vento. Modelos quânticos (QNNs) estão sendo usados para melhorar a precisão dessas previsões rápidas.

Prompt Engineering A arte de criar as instruções (prompts) que são enviadas para o modelo de IA. Em um sistema RAG, o prompt é montado dinamicamente, combinando a pergunta do usuário com os "chunks" de texto recuperados do banco de dados, instruindo a IA a responder apenas com base naquele contexto.

QLSTM (Quantum Long Short-Term Memory) Uma versão quântica das redes neurais LSTM, que são especializadas em aprender sequências temporais. As QLSTMs utilizam circuitos quânticos para processar informações, oferecendo vantagens como convergência mais rápida durante o treinamento e melhor capacidade de capturar padrões complexos em séries temporais de geração de energia solar e eólica.

QNN (Quantum Neural Network) Redes Neurais Quânticas são algoritmos de aprendizado de máquina que incorporam princípios da mecânica quântica. Elas são usadas, por exemplo, como extractores de características em dados meteorológicos, identificando correlações sutis que modelos clássicos podem perder, melhorando a previsão de geração renovável.

Qubit (Bit Quântico) A unidade fundamental de informação na computação quântica. Diferente de um bit clássico que é 0 ou 1, um qubit pode estar em um estado de superposição, representando ambos simultaneamente. Isso permite que computadores quânticos processem uma quantidade massiva de combinações possíveis ao mesmo tempo.

QUBO (Quadratic Unconstrained Binary Optimization) Um formato matemático padrão para formular problemas de otimização de modo que possam ser resolvidos por computadores de Annealing Quântico. Problemas reais, como o agendamento de baterias ou fluxo de potência, são convertidos para equações QUBO (variáveis binárias 0 ou 1) para serem processados pelo hardware quântico.

RAG (Retrieval-Augmented Generation) Geração Aumentada por Recuperação é uma arquitetura que combina um modelo de linguagem (LLM) com um sistema de busca em dados externos. Antes de responder a uma pergunta, o sistema "recupera" informações relevantes de uma base de conhecimento confiável (como manuais da empresa) e as usa para "aumentar" o conhecimento da IA, gerando respostas precisas e atualizadas sem precisar retreinar o modelo.

Retriever (Recuperador) O componente de um sistema RAG responsável por varrer o banco de dados e selecionar os documentos mais relevantes para a consulta do usuário. A qualidade do retriever é determinante para o sucesso do sistema: se ele falhar em encontrar a informação certa, a IA não conseguirá responder corretamente.

Store-Now-Decrypt-Later (SNDL) Uma estratégia de ataque cibernético onde hackers roubam dados criptografados hoje, mesmo sem ter a chave para lê-los, com a intenção de guardá-los e decifrá-los no futuro, quando computadores quânticos poderosos estiverem disponíveis para quebrar a criptografia atual. Isso gera uma urgência para a adoção de criptografia pós-quântica.

Tunelamento Quântico (Quantum Tunneling) Um fenômeno da mecânica quântica onde uma partícula consegue atravessar uma barreira de energia que seria intransponível pela física clássica. Algoritmos de Annealing Quântico utilizam esse efeito para escapar de "armadilhas" (mínimos locais) durante a otimização, permitindo encontrar a melhor solução global para problemas da rede elétrica de forma mais eficiente.

Unit Commitment (Compromisso de Unidades) O problema complexo de planejar quais geradores de energia devem ser ligados ou desligados em cada período para atender à demanda prevista. Com a entrada de energias renováveis variáveis, esse problema torna-se muito difícil para computadores clássicos, sendo um dos principais candidatos para otimização via computação quântica.

Vector Database (Banco de Dados Vetorial) Um tipo de banco de dados otimizado para armazenar e buscar embeddings (vetores). É onde o "conhecimento" do sistema RAG é guardado. Ele permite realizar buscas por similaridade semântica em altíssima velocidade, encontrando documentos que têm significado próximo à pergunta do usuário.

VQE (Variational Quantum Eigensolver) Um algoritmo híbrido quântico-clássico utilizado para simular química quântica. No setor de energia, é aplicado para calcular a energia do estado fundamental de moléculas, acelerando a descoberta de novos materiais para baterias (como eletrólitos de estado sólido) e catalisadores para hidrogênio verde.