

# AWS HealthScribe (visualização)

## Gere automaticamente notas clínicas a partir de conversas entre médico e paciente

Aumente a produtividade clínica com notas geradas por IA que são mais fáceis de consultar, editar e finalizar.

Use IA de forma responsável em ambientes clínicos com referências de transcrição rastreáveis para cada nota gerada por IA.

Simplifique a implementação com um serviço de IA conversacional e generativo unificado e integrado em seu aplicativo.

O **AWS HealthScribe** é um serviço qualificado para HIPAA que permite aos fornecedores de software de saúde criar aplicativos clínicos que geram notas clínicas automaticamente por meio da análise de conversas entre pacientes e médicos.

### Casos de uso

#### Reduza o tempo de documentação

Capacite os médicos a preencher rapidamente a documentação com notas clínicas geradas por IA que são mais fáceis de validar quanto à precisão e finalizar.

#### Aumente a eficiência do fluxo de trabalho do escriba médico

Equipe os escreventes com transcrições e notas clínicas geradas por IA, juntamente com áudio de

consulta, para agilizar o tempo de entrega da documentação

Recapitulação da consulta amigável ao paciente

Crie uma experiência que permita aos pacientes relembrar rapidamente os principais destaques de suas conversas em seu aplicativo.

## Machine Learning: Como Funciona e Qual a Importância Para as Empresas

[Blog](#) / Machine Learning: Como Funciona e Qual a Importância Para as Empresas

Machine learning, ou aprendizado da máquina, é uma área da ciência da computação que permite automatizar respostas ao usuário a partir de inteligência artificial e big data.

Você certamente já ouviu falar em machine learning.

Mas será que domina esse conceito tecnológico?

Afinal, o machine learning tem influência direta em muitos momentos do seu dia a dia.

Agora mesmo, em sua navegação até este artigo: essa jornada certamente passou pelo aprendizado de máquina e pela inteligência artificial.

Percebe como o conceito permeia praticamente todas as suas interações com a tecnologia – e como sua importância tende a ser cada vez maior?

A má notícia é que esse subcampo da ciência da computação é um assunto complexo.

A boa notícia é que eu preparei um guia completo que vai desbrinchar cada aspecto desse tema e apresentar, passo a passo, como encará-lo a partir de agora.

## Você quer resultados imediatos?

Minha agência pode fazer todo o trabalho pra você. Somos especialistas em:

- **SEO** - Colocamos seu site no topo das pesquisas do Google
- Mídia Paga** - Fazemos seu negócio alcançar quem importa

### Primeiro, é importante dar um passo atrás...

Antes de continuar, se você quer aumentar suas vendas e saber quais são as melhores estratégias para promover seu negócio online, [clique aqui para receber o Guia Completo de Marketing Digital](#).

## O que é machine learning? Conceito

**Machine learning, ou aprendizado de máquina, é uma forma de análise de dados orienta os computadores a aprenderem por conta própria, para que aprimorem seu desempenho diante de problemas específicos.**

Ou seja: ao invés de serem programadas apenas para ações específicas, as máquinas usam [algoritmos](#) complexos para tomar decisões e interpretar dados, executando tarefas automaticamente.

Esses programas conseguem aprender a partir do alto poder de processamento de [dados](#), sem intervenção humana. Assim, aperfeiçoam suas tarefas conforme recebem novas informações, como alunos aplicados e incansáveis.

**O machine learning faz parte do extenso campo da Inteligência Artificial (IA), que promete movimentar US\$ 59,8 bilhões no mundo todo até 2025, segundo o [estudo](#) da Tractica.**

Inclusive, esse mercado gigantesco já está presente no seu dia a dia. No machine learning, o material de estudo das máquinas são os dados. Quanto mais dados alimentarem os sistemas, mais perguntas serão feitas, e mais respostas surgirão para solucionar problemas.

É por isso que o machine learning alcança seu pleno potencial com o [Big Data](#), o [armazenamento](#) e processamento de volumes gigantescos de dados. Logo, os algoritmos inteligentes conseguem fazer uma varredura completa nessa imensidão de dados para encontrar padrões e chegar a previsões inimagináveis. Para você ter uma ideia, nós produzimos 2,5 quintilhões de bytes de dados todos os dias.

Como consequência, 90% dos dados mundiais foram criados somente nos últimos dois anos ([Domo](#)). Imagine aonde isso vai parar.

## **O começo de tudo – qual a história do Machine learning?**

**O machine learning funciona por meio dos algoritmos que mencionei acima.**

Basicamente, um [algoritmo](#) é uma sequência de ações precisas, como um passo a passo que resolve uma tarefa automaticamente. Cada algoritmo aciona um comando diferente para lidar com os dados que a máquina recebe, e a combinação entre eles gera o machine learning.

É assim que o Google Maps indica o caminho mais rápido com base na sua localização e eventos próximos e a Amazon recomenda produtos de acordo com seus hábitos.

## Importância do machine learning

O aprendizado de máquinas é, sem dúvida, um dos mais bem-vindos avanços que a tecnologia digital nos trouxe.

Felizmente, cenários apocalípticos como o retratado na série de filmes “*O Exterminador do Futuro*” até agora não passam de produto da imaginação e engenhosidade dos grandes cineastas. Na verdade, a vida real mostra exatamente o oposto: máquinas e computadores incríveis e colaborativos que ajudam a realizar tarefas antes trabalhosas demais ou com alta incidência de falha humana.

Inclusive, um [estudo da Oracle](#) confirma que as pessoas nas empresas confiam mais no que dizem as máquinas do que em seus próprios chefes e gestores.

E você, é também entusiasta a esse ponto?

## A evolução do machine learning

Embora não receba esse título, pode-se dizer que o “pai” do conceito de aprendizado de máquinas foi Alex Turing, um dos mais brilhantes matemáticos de todos os tempos.

Entre seus muitos feitos notáveis, destaca-se a descoberta da localização precisa das tropas nazistas no Dia D.

Esse grande cientista ainda ficaria mais conhecido por ter sido o criador da inteligência artificial, a precursora do Machine Learning, na década de 1950.

A propósito, Turing também é de certa forma o responsável pela criação do próprio conceito de algoritmo, embutido na famosa “Máquina de Turing”. O tempo passou e, em 2010, o Instituto de Tecnologia de Massachusetts (MIT) antecipou a evolução do setor ao publicar [um artigo sobre o uso de algoritmos](#) para tratar de dados gerados por cartões de crédito.

Depois disso, a capacidade de aprendizado das máquinas só cresceu, sendo hoje amplamente utilizada pelo Google e pelas já citadas plataformas Netflix e Youtube.

## **Tipos e métodos mais populares de machine learning**

Para cada problema, há um algoritmo de aprendizado ideal para encontrar a solução.

Confira os diferentes tipos de machine learning.

### **Aprendizado supervisionado**

No aprendizado supervisionado, o sistema recebe um conjunto prévio de dados que contém a resposta correta.

Ou seja: os problemas e soluções já estão definidos e associados, e tudo o que a máquina tem que fazer é mostrar o resultado certo a partir das variáveis.

Um exemplo básico é a [busca de imagens do Google](#), na qual o algoritmo localiza a origem da imagem e outras semelhantes.

### **Aprendizado não-supervisionado**

Como aprendizado não-supervisionado, ocorre o contrário: não há um resultado específico esperado ou resposta correta.

Isso quer dizer que o cruzamento dos dados é imprevisível e depende das variáveis inseridas no sistema.

Por exemplo, em uma pesquisa sobre hábitos de consumo, é preciso agrupar informações como registros de compras, frequência e perfil do cliente para encontrar padrões.

Nesse tipo de machine learning, cada movimento é uma descoberta – por isso, também é muito mais complexo.

## Aprendizado semi-supervisionado

Já o aprendizado semi-supervisionado combina os dois tipos de dados que vimos acima: rotulados e não rotulados.

Assim, há uma pequena quantidade de respostas definidas entre as incertezas, que ajudam a direcionar as descobertas da máquina.

## Aprendizado por reforço

Por fim, o aprendizado por reforço é diferente de todos os tipos anteriores, pois não possui nenhum conjunto prévio de dados.

É como se um robô fosse solto em um lugar desconhecido, onde passa a realizar testes para coletar impressões e se adaptar ao ambiente.

Gosto de usar como exemplo um programa financeiro que monta [portfólios](#) de ações.

Esse software é capaz de melhorar cada vez mais suas combinações de ativos conforme analisa o retorno positivo ou negativo do ambiente.

Ou seja: a máquina estuda o retorno financeiro e a evolução do mercado para determinar as melhores soluções, sem um conjunto de treinamento específico.

## Como escolher o melhor algoritmo?

O melhor algoritmo depende exclusivamente do problema a ser solucionado, pois não há um padrão que funcione em todos os casos. Lembre-se de que as máquinas não fazem o que você quer: elas fazem o que você manda. Com isso, quero dizer que a inteligência artificial depende 100% da inteligência humana.

É você quem treina a máquina e decide qual tipo de [algoritmo](#) vai chegar aos resultados esperados.

Por isso, você precisa conhecer a fundo o problema e seus possíveis caminhos antes de ensinar a máquina a resolvê-lo.

## Para que serve o machine learning?

As aplicações do machine learning vão desde as sugestões a usuários da internet até o desenvolvimento de carros autônomos e identificação de estrelas pela NASA.

Estes são alguns dos usos mais comuns:

- Motores de busca online
- Coleta e análise de dados
- Detecção de spam
- Organização e classificação de informações
- Soluções em automação
- Reconhecimento biométrico e de [voz](#)
- Sistemas de recomendação
- Sistemas de vigilância
- Robôs e veículos autônomos.
- 

## 6 benefícios do machine learning nos negócios

Os benefícios do machine learning nos negócios justificam o alto investimento das empresas. Veja quais são as vantagens dessa tecnologia.

### Decisões mais rápidas

Tomar a decisão certa antes da concorrência pode mudar o destino da empresa.

Por isso, o machine learning tem sido fundamental nesse processo, mostrando os caminhos mais inteligentes e providências imediatas aos gestores.

Afinal, a máquina consegue enxergar muito mais longe ao processar bilhões de dados.

## **Adaptabilidade**

Os algoritmos mostram resultados aqui e agora, e não apenas em relação aos dados históricos. Assim, os gestores conseguem ajustar o curso do negócio em tempo real, no ritmo acelerado das mudanças.

## **A empresa algorítmica**

A “empresa algorítmica” é uma fábrica de inovação em alta velocidade. Com inúmeros algoritmos trabalhando pelos objetivos do negócio e aprendendo mais a cada dia, o caminho do sucesso é garantido. Quanto mais alto o nível de automação, melhor será a capacidade da empresa de inovar em modelos de negócio, produtos e serviços.

## **Insights mais profundos**

Ainda não descobrimos como processar bilhões de informações de uma vez com o cérebro humano, mas temos as máquinas para fazer esse trabalho. Assim, chegamos a insights muito mais profundos, que jamais seríamos capazes de identificar.

## **Eficiência**

O machine learning focado em eficiência pode revolucionar os processos da empresa. Basta pensar em algoritmos inteligentes fazendo previsões minuciosas e automatizando tarefas para reduzir custos e melhorar os resultados. E claro, praticamente eliminando o erro humano do processo.

## **Melhores resultados**

Por fim, o machine learning é a fórmula para identificar oportunidades e alavancar os resultados das empresas.

De acordo com a Accenture, a inteligência artificial vai aumentar a lucratividade em 38% e gerar mais de US\$ 14 trilhões em lucro

extra até 2035. É isso que eu chamo de retorno sobre o investimento.

## **Existe alguma desvantagem no machine learning?**

Já diz a sabedoria popular que a diferença entre o remédio e o veneno é a dosagem.

No caso do aprendizado de máquinas, esse raciocínio se aplica perfeitamente, já que, como qualquer solução, ele não é a resposta para todos os problemas.

O principal está em saber utilizá-lo bem para que se possa extrair apenas benefícios.

Portanto, a desvantagem em machine learning não está na tecnologia, mas na forma como as pessoas a usam.

Além disso, embora realmente as máquinas tenham capacidades superiores aos humanos em alguns aspectos, nada substitui o talento individual e a empatia.

## **Qual a diferença entre mineração de dados e machine learning?**

A mineração de dados e machine learning são tecnologias muito próximas, mas possuem diferenças significativas.

Enquanto o machine learning permite a construção de sistemas que aprendem com os dados, a mineração de dados extrai informações e organiza o conjunto de dados que será utilizado.

Em outras palavras, o primeiro é focado na análise e predição, e a segunda na descoberta de propriedades desconhecidas dos dados.

## A importância da mineração de dados para machine learning

O deep learning está em uma camada mais profunda do machine learning, em que as redes neurais utilizadas são parecidas com as do cérebro humano.

Essas redes artificiais imitam a complexidade e funcionamento dos neurônios, e com isso chegam a soluções extraordinárias.

É por meio do deep learning que os carros autônomos se tornam, cada vez mais, autônomos, por exemplo.

## Qual a diferença entre machine learning e inteligência artificial?

Essa é fácil: o machine learning é um dos pilares desse campo tecnológico gigantesco chamado inteligência artificial.

Já a inteligência artificial pode ser definida como a extensão da inteligência humana por meio de máquinas capazes de simular nosso raciocínio.

O [artigo](#) polêmico de Alan Turing sobre máquinas que pensam foi apenas o começo da IA, que explodiu no mundo todo a partir de 2015.

## Diferença entre machine learning e Big Data

Embora não seja um conceito assim tão recente, o aprendizado de máquinas frequentemente é confundido com o de [Big Data](#).

Nesse caso, o que é preciso saber é que são ideias distintas, mas que têm uma relação entre si.

Machine learning, como já vimos, é a propriedade que as máquinas têm de aprender e de se tornar mais inteligentes com o tempo.

Já o Big Data é um conceito que remete ao gigante repositório de dados online gerados pelas pessoas conectadas no mundo todo, incluindo seu levantamento, organização, análise e acessibilidade.

Portanto, pode ser compreendido como uma das fontes de onde as máquinas inteligentes aprendem novas funções e extraem informação.

## **Qual a diferença entre Deep Learning e Machine learning?**

Outra confusão bastante comum é entre a definição de machine learning e deep learning.

Sobre machine learning, não vou me alongar muito, já que o conceito foi explicado.

Por isso, cabe apenas expor as diferenças para o termo deep learning que, na verdade, trata-se de uma forma ainda mais avançada de [Inteligência Artificial \(IA\)](#).

Sendo assim, uma máquina capaz de se aprimorar por deep learning apresenta habilidades superiores, já que adota um modelo de aprendizagem preditiva.

Isso significa que ela não depende mais de receber dados inseridos por um programador ou por meio da coleta passiva de informação.

Por deep learning, a máquina é capaz de entender sozinha o contexto e de se antecipar em busca de soluções.

## **A importância da mineração de dados para machine learning**

Sem a mineração de dados, estaríamos perdidos no infinito do Big Data. Essa tecnologia nos permite separar ruídos caóticos e repetitivos para classificar e organizar os dados, transformando um conjunto desconexo em informações comprehensíveis. Para isso, a mineração utiliza técnicas como o clustering (agrupamento de dados), regras de associação e detecção de anomalias.

## **Exemplos práticos de machine learning**

Existem muitos exemplos de casos em que a aplicação de machine learning fez toda a diferença nos negócios.

E o interessante é que não tem um nicho específico que se beneficie mais.

Praticamente toda atividade humana tem resultados incrivelmente positivos quando aplica com sucesso as máquinas inteligentes em suas [estratégias](#) e operações.

Conheça, então, algumas delas.

## Recomendação de conteúdo

Uma das aplicações que considero mais incríveis do Machine Learning é como sistema para orientar motores de busca na recomendação de conteúdos.

Essa é uma aplicação de aprendizado de máquina que usa modelagem de dados e algoritmos complexos buscando o tempo todo estipular uma nota (rating) que qualifique a preferência de um usuário.

Para isso, existem basicamente três tipos de algoritmos principais: sistemas híbridos, filtragem [baseada em conteúdo](#) e filtragem colaborativa.

Esta última baseia as recomendações a partir de itens com os quais usuários com perfis parecidos tenham tido alguma interação.

Já a filtragem baseada em conteúdo toma como referência conteúdos anteriormente consumidos pelo próprio usuário para fazer novas indicações.

Finalmente, nos sistemas híbridos, ambos os tipos de filtragem são empregados para recomendar anúncios e conteúdos diversos.

## Tradução de textos

Outra aplicação fantástica do aprendizado de máquinas é na [tradução de textos](#).

Acredito que essa é uma das funcionalidades que mais evoluiu nos últimos anos, considerando a precisão de ferramentas como o Google Tradutor.

Afinal, uma tradução bem feita deve contextualizar as palavras, expressões, gramática, emprego de verbos, pronomes, entre outras funções sintáticas. É uma tarefa bastante complexa que, com machine learning, torna-se possível mesmo no caso dos idiomas mais distantes. Hoje podemos ter traduções instantâneas muito próximas do sentido real de um texto originalmente escrito em um idioma no qual não temos nenhum conhecimento.

## Análise de crédito

A Serasa Experian, gigante do mercado de crédito, desenvolveu um poderoso mecanismo para antecipar o risco em operações financeiras com base em machine learning.

Chamado de Ascend Analytics On Demand, o software é capaz de apontar com grande precisão o perfil de um consumidor, indicando-o ou não para a compra a prazo ou para receber ofertas de crédito.

## Automobilismo

O alcance do machine learning não conhece limites, podendo ser aplicado até nas competições automobilísticas.

Foi isso que fez a equipe Mercedes-AMG Petronas Motorsport, que passou a usar máquinas inteligentes para medir a performance dos seus carros.

Dessa forma, aumentou a durabilidade dos componentes, com ênfase nas trocas de marchas.

Resultado: os engenheiros conseguiram desenvolver modelos de câmbio que tornaram sua troca mais rápida em cerca de 50 milissegundos.

Pode não parecer muito, mas, em competições de altíssima performance, é um ganho importante.

## Detecção de fraudes

Boa parte dos grandes bancos mundiais usam mecanismos desenvolvidos com base em machine learning para detectar fraudes em suas operações.

É o que acontece, por exemplo, em compras com cartão de crédito em que a operadora faz contato com o cliente para saber se é realmente ele quem está fazendo uma aquisição.

## Quem está usando machine learning?

As principais indústrias, universidades, organizações e instituições investem na mineração de dados para potencializar suas [estratégias](#).

Veja setores nos quais o machine learning se destaca:

### Serviços financeiros

Como já destaquei, os bancos e instituições financeiras estão usando a mineração de dados para entender a fundo sua base de [clientes](#) e bilhões de transações.

As principais vantagens são a previsão de riscos de mercado, detecção rápida de fraudes e gestão efetiva de compliance.

### Governo

Para os governos, a mineração é fundamental para qualificar dados de milhões de cidadãos e tomar decisões mais assertivas.

No Brasil, a Receita Federal ganhou o prêmio [As 100+ Inovadoras no Uso de TI](#) da IT Mídia, graças ao uso da mineração de dados para aprimorar o sistema de arrecadação.

### Operadoras de saúde

Já o setor da saúde se destaca pela previsão de US\$ 6,6 bilhões em investimentos na inteligência artificial até 2021, segundo a [Accenture](#).

As principais aplicações da mineração de dados na área são a triagem de risco de saúde, avaliação de dados médicos e monitoramento da saúde pública.

## **Marketing e vendas**

A área de [marketing](#) e vendas é uma das mais impactadas pela mineração de dados, dando origem ao conceito de marketing mining.

Nesse caso, a [tecnologia](#) é aplicada para conhecer melhor o consumidor, identificar a percepção da marca e criar campanhas de sucesso.

Inclusive, é possível que 85% das relações entre consumidores e empresas não incluam a interação humana até 2020, [conforme a Gartner](#).

## ***Search Engine Optimization (SEO)***

Você lembra do tempo em que o abuso de “keyword stuffing”, ou seja, abarrotar os textos com excesso de repetição das palavras-chave, dava certo?

Muitas páginas tinham sucesso em atrair tráfego com essa prática típica de [Black Hat](#).

Graças à evolução do Machine Learning, esse tipo de estratégia hoje em dia não apenas deixa de ter bons resultados como provoca punições.

Isso tornou-se possível porque, com as máquinas capazes de assimilar informação, o peso das palavras-chave se relativizou.

Hoje, além de pautar o ranqueamento de conteúdo nas keywords usadas, os algoritmos também conseguem detectar se ele é bem escrito e relevante de fato.

Isso é ótimo para quem trabalha bem com SEO, já que tira do páreo quem usa de práticas desonestas para gerar tráfego e audiência.

## ***Campanhas de PPC (pagamento por clique)***

Além dos conteúdos em blogs, o aprendizado de máquinas também já é utilizado para determinar o alcance das campanhas pagas em plataformas como o [Google Adwords](#).

Como já mencionei, o que parece leitura de pensamento nada mais é do que os sofisticados algoritmos trabalhando para levar a você indicações de anúncios de acordo com suas preferências.

Uma evolução das mais louváveis para quem trabalha com marketing digital, porque torna as campanhas ainda mais relevantes para o usuário.

Para o consumidor, também é ótimo, já que ele deixa de ser obrigado a assistir ou visualizar anúncios que nada têm a ver com o seu perfil.

## ***Marketing de conteúdo***

Uma das qualidades do marketing de conteúdo que não canso de exaltar é que, com ele, as marcas conseguem dialogar com públicos muito mais segmentados.

Isso sem contar que, em campanhas e conteúdos na web, a mensuração dos resultados é sempre precisa, permitindo conhecer dados da maior relevância sobre leads e consumidores.

Tudo isso só é possível graças ao Machine Learning, que permite uma compreensão mais rápida do comportamento de um usuário.

Também permite saber o que faz com que as pessoas cheguem aos seus anúncios e conteúdos, ajudando assim a aperfeiçoar estratégias de marketing digital.

Dessa forma, você torna-se capaz de desenvolver conteúdos que sejam relevantes, aumentando assim suas conversões e o market share. O Google evoluiu bastante, a ponto não só de coibir práticas de stuffing como até de detectar quando um link é comprado.

Essa evolução veio com o algoritmo Penguin em 2015, pelo qual o maior motor de busca de todos os tempos aprendeu finalmente a identificar um link suspeito.

Dessa forma, assim como o peso das palavras-chave hoje é relativo, a inserção de um backlink por si só não garante autoridade a um site, tampouco posições melhores na SERP.

O que passa a valer cada vez mais é a citação natural de uma página, desde que seja de forma contextualizada e vinculada a soluções efetivas para o público a quem se destina.

## ***Redes sociais***

Não é só o Google que se beneficia dos avanços em Machine Learning.

Você já deve ter observado, por exemplo, que o feed de notícias do Facebook e Instagram, entre outras redes, está cada vez mais antenado às suas preferências.

Se há algum tempo o que se via era um festival de conteúdos e publicações sem qualquer utilidade (muitas delas ofensivas, inclusive), hoje existe uma curadoria bem mais sofisticada.

Isso porque os algoritmos das [redes sociais](#) hoje estão preparados para usar filtros muito mais inteligentes, permitindo assim que só conteúdos que valem a pena sejam exibidos.  
Por outro lado, esse tipo de avanço permite que fake news se propaguem, com todas as suas consequências perigosas.

## ***Qualificação de leads***

Claro que os processos de marketing como um todo ganham muito com a aplicação de Machine Learning.

Como já comentei, hoje os algoritmos conseguem detectar com muito mais precisão o comportamento de consumo dos clientes.

Dessa forma, é possível criar conteúdos e anúncios adequados para cada fase do [funil de marketing](#).  
Outra vantagem é que, com as máquinas inteligentes, tornou-se mais fácil gerar Sales Qualified Leads (SQL) e [Marketing Qualified Leads \(MQLs\)](#).

Aliás, se esse é um tema que desperta muitas dúvidas em você, fica a recomendação de leitura do artigo em que eu mostro [como fazer a qualificação de leads](#).

## **Petróleo & gás**

Na indústria de petróleo e gás, os dados são utilizados para os mais variados propósitos, desde previsão de riscos até garantia de compliance.

Alguns objetivos são aumentar a eficiência dos processos, obter recomendações sobre os poços que precisam de mais atenção e automatizar ordens de trabalho.

## Transportes

No setor de transportes, a promessa da mineração de dados está no setor de logística.

Isso porque a enorme quantidade de informações geradas nessas operações ainda é pouco explorada.

Com as tecnologias certas, é possível aumentar a eficiência operacional, prever demandas sazonais e melhorar as redes de distribuição.

## 4 Aplicações de uso do machine learning

Se ainda restam dúvidas sobre o uso do machine learning, o que não faltam são exemplos.

### 1-Banco de dados autônomo

O banco de dados autônomo é capaz de listar várias tarefas de forma totalmente automatizada, graças ao machine learning.

Essa inovação descarta a indisponibilidade por falha humana e ainda libera tempo do administrador para tarefas mais importantes.

### 2\_ Combate a fraudes em sistemas de pagamento

As tentativas de fraude com cartões de crédito e meios de pagamento são um problema sério para as empresas.

Felizmente, o machine learning ensina as máquinas a identificar e combater esses golpes a tempo de evitar prejuízos.

## **3- Tradução de textos**

Os tradutores automáticos estão ficando cada vez mais precisos com o machine learning, a ponto de reconhecer contextos e expressões.

O profissional de tradução ainda é indispensável, mas seu trabalho certamente ficou mais fácil.

## **4- Recomendação de conteúdo**

Essa você conhece muito bem: são as recomendações de músicas, vídeos e publicações das suas plataformas preferidas.

Com o machine learning, os algoritmos ajudam você a descobrir um mundo de conteúdos com base no seu histórico e preferências.

## **O que é preciso para criar bons sistemas de machine learning?**

Resumidamente, um bom sistema de machine learning tem cinco características:

- Algoritmos
- Processos automatizados e iterativos
- Escalabilidade
- Capacidade de preparação de dados
- Modelagem conjunta.

Mas você não pode se esquecer de um detalhe muito importante: não adianta construir algoritmos poderosos se os dados não tiverem a qualidade necessária.

A máxima dos dados continua valendo: garbage in, garbage out (lixo entra, lixo sai).

Essa expressão foi criada pelo técnico da IBM George Fuechsel, para nos lembrar de que os computadores não questionam a qualidade dos dados.

Ou seja: se você alimentar um algoritmo com dados imprecisos, terá [resultados](#) inúteis.

## Quais as tendências do Machine Learning para o futuro?

Nem as próprias máquinas podem prever até onde o machine learning nos levará, mas tenho alguns palpites.

Com a [Internet das Coisas](#), é natural que a inteligência artificial entre no pacote, permitindo que relógios, televisores e geladeiras aprendam sobre nossos hábitos.

Outra tendência promissora é o Processamento de Linguagem Natural, que tornará realidade a ideia de conversar com uma máquina sem a preocupação com códigos.

Os hardwares também vão evoluir no mesmo ritmo para aumentar o poder de processamento, como já mostram os recentes chips de inteligência artificial.

Aliás, vem aí o chip da Intel em parceria com o Facebook, [noticiado](#) em janeiro pelo G1.

E se os algoritmos andam exibindo anúncios duvidosos, não se preocupe: a precisão das recomendações vai melhorar muito nos próximos anos.

## O começo de tudo – História do Machine learning

Nossa história começa na década de 1950, quando o pai da computação, [Alan Turing](#), fez a célebre pergunta: “As máquinas podem pensar?”.

Nessa época, ele desenvolveu o famoso [Teste de Turing](#), que testava a capacidade das máquinas de raciocinarem como seres humanos.

Alguns anos depois, em 1952, o engenheiro do MIT e pioneiro em inteligência artificial [Arthur Samuel](#) criou o primeiro programa capaz de aprender.

Tratava-se de um jogo de damas que ia melhorando seu desempenho a cada partida, estudando movimentos e propondo novas estratégias.

Esse passo foi fundamental para que, em 1959, Samuel usasse pela primeira vez o termo machine learning.

Nesse momento, a pergunta de Turing foi respondida: sim, as máquinas podem reproduzir o raciocínio humano.

Desde então, os computadores ficaram cada vez mais inteligentes, e a internet multiplicou essa capacidade.

## **Relação entre Python e machine learning**

Ainda que as máquinas sejam inteligentes, é necessário antes a intervenção de um programador humano para possibilitar isso.

Para programar um equipamento capaz de aprender, esse profissional usa uma linguagem com a qual insere diretrizes e comandos a serem seguidos.

No caso da aprendizagem de máquinas, a linguagem mais amplamente utilizada é a Python, em virtude da sua simplicidade.

Outra característica que a torna interessante é a sua grande quantidade de bibliotecas, que servem como códigos prontos a partir dos quais podem ser programadas diversas funções.

## Mitos e verdades sobre machine learning

Não deixa de ser engraçado quando escuto ou leio algumas pessoas comentando que o aprendizado de máquinas nos levaria a um apocalipse tal como em Exterminador do Futuro.

Nada mais equivocado, até porque as máquinas só fazem aquilo para o que elas foram programadas. O pessoal se impressiona demais com filmes de ficção.

Até o momento, é impossível um computador tomar a iniciativa de coordenar por livre e espontânea vontade um ataque armado contra os seres humanos.

Outro equívoco que vejo ser cometido com alguma frequência é em relação ao [uso dos dados](#).

Se eles não forem qualificados, será impossível que uma máquina aprenda ou interprete algo a partir deles.

Em outras palavras: não basta ter um algoritmo e esperar que ele “se vire” sozinho. Se ele não for abastecido com dados minimamente tratados, não poderá realizar o seu trabalho, que é ler esses dados e gerar insights e soluções.

## 3 dicas para você se adaptar ao machine learning

Agora que você já sabe tanto sobre Machine Learning, é claro que eu não deixaria você na mão, sem dicas úteis e práticas.

Em um contexto no qual o Big Data ganha cada vez mais força, é preciso estar pronto para aproveitar as infinitas possibilidades que ele gera.

Veja a seguir como fazer isso.

## Tenha um site receptivo

Provavelmente você já deu de cara com os simpáticos [robôs de atendimento](#) quando acessou algum site na web.

Esses robôs também são desenvolvidos a partir de Machine Learning, já que são capazes de assimilar padrões de comportamento.

Nesse contexto, seu site precisa ser não só responsivo, como também receptivo.

Ou seja, capaz de prestar um atendimento online sempre que solicitado pelo usuário.

## Faça a otimização para pesquisa local

Os algoritmos do Google evoluíram a ponto de conseguirem identificar o que é uma busca local.

Portanto, se o seu negócio atende a uma região e tem um site que não está otimizado para ser rastreado para buscas desse tipo, é bom arregaçar as mangas e providenciar logo essa otimização.

Já aproveite e, depois desta leitura aqui, confira em um artigo completo [como fazer SEO local](#) do jeito certo.

## Se prepare para pesquisas de voz

O interesse das pessoas pelas [pesquisas por voz](#) do Google têm aumentado, como aponta uma [pesquisa da Speechmatics](#).

Sendo assim, quem quiser se manter no topo dos resultados das pesquisas orgânicas e pagas precisará garantir que seu site seja encontrado por esse tipo de pesquisa também.

## **Perguntas Frequentes Sobre Machine Learning**

### **O que é machine learning?**

Machine learning, ou aprendizado de máquina, é uma forma de análise de dados orienta os computadores a aprenderem por conta própria, para que aprimorem seu desempenho diante de problemas específicos

### **Como funciona o machine learning?**

O machine learning funciona por meio dos algoritmos que mencionei acima. Basicamente, um algoritmo é uma sequência de ações precisas, como um passo a passo que resolve uma tarefa automaticamente.

### **Quais os principais tipos de machine learning?**

Confira os diferentes tipos de machine learning:

- Aprendizado supervisionado;
- Aprendizado não-supervisionado;
- Aprendizado semi-supervisionado;
- Aprendizado por reforço.

### **Para que serve o machine learning?**

Estes são alguns dos usos mais comuns para o machine learning:

- Motores de busca online;
- Coleta e análise de dados;
- Detecção de spam;
- Organização e classificação de informações;
- Soluções em automação;
- Reconhecimento biométrico e de voz;
- Sistemas de recomendação;
- Sistemas de vigilância;
- Robôs e veículos autônomos.

## **Conclusão**

Computadores que aprendem por conta própria soavam como ficção científica algumas décadas atrás.

Mas aqui estamos nós, conversando com assistentes virtuais em celulares e nos acostumando à ideia de carros que dirigem sozinhos. Cada vez mais, a inteligência artificial soa menos artificial, não é mesmo?

**O smartphone se transforma em uma extensão da nossa capacidade de processamento de dados, a um segundo de distância do nosso input.**

Esse dispositivo nos conecta ao carro, ao apartamento, ao dinheiro e ao último lançamento da nossa série favorita. Como entusiasta da tecnologia, não vejo a hora de aproveitar ainda mais oportunidades que as máquinas inteligentes nos reservam.

*Já está com seu radar de tendências atualizado para captar todas as novidades trazidas pelo machine learning?*

*Deixe aqui um comentário com suas ideias e seus insights sobre o assunto.*

## O que é Machine Learning?

### Introdução

Machine Learning, será que esse é só um termo da moda? Entenda qual o conceito do Machine Learning nesse bate-papo.

#### Entenda Machine Learning com um caso real

Guilherme, já vou começar a contar uma história, dessas que eu gosto muito, de **machine learning** que todo mundo já conhece, mas vale a pena.

Tem um desses sites muito grandes de e-commerce americano, que há alguns anos, começou a rodar esses **algoritmos** para tentar descobrir o que as pessoas vão comprar num futuro muito próximo. E uma das clientes que eles tinham, começou a navegar muito no site em produtos relacionados a bebês. Então começou a acessar mamadeiras, um pouco de fraldas, roupas de tamanhos maiores e tudo que está próximo do mundo da maternidade.

O que aconteceu? O algoritmo deste site funcionou muito bem para **recomendar produtos** para ela. Eles têm uma estratégia muito mais agressiva, em vez de no site apenas ficar mostrando “eu

*recomendo que você compre esse produto*”, o que eles fizeram: passado um mês, eles mandaram um encarte especial para ela, com descontos e cupons para comprar roupas de neném, fralda, entre outros produtos relacionados.

E adivinha só? Os pais dessa menina acabaram abrindo esse encarte e descobriram a gravidez dela através dessa mensagem de venda, falaram “*ué, porque a minha filha tá recebendo esse tipo de correspondência?*” e não era uma correspondência solicitada, era uma correspondência que os robôs da matrix acabaram decidindo que deveria ser enviado para essa cliente, porque a **probabilidade dela comprar** nesse tempo curto desde a última visita no site era muito grande.

É óbvio, esse é um caso em que os robôs acabaram com a humanidade, mas eu acho que tem muitos casos que esse tal de **aprendizado computacional** funciona muito bem.

Você tem algum exemplo, o que você pode contar para gente?

Posso complementar um pouquinho essa história até. A história é super romantizada, é super bonita, etc. e, infelizmente, tirava o direito da própria mulher, dela dizer para os pais, no momento que ela desejava, sobre a gravidez, né, e para as outras pessoas, nessa situação específica.

Mas tem que se pensar: **qual é o objetivo final da empresa** com essa sacada?

*Pesquisa na Microsoft: Machine Learning – Hipsters #161*

Mas além de vender mais, por que vender mais? Na fase da maternidade, pais e mães estão mais suscetíveis a comprar da maneira mais cômoda, onde já estão acostumados. Então, se você conquista a pessoa antes dela ter o filho ou a filha, quando ela está nessa bagunça de acordar de madrugada todo dia, etc., a pessoa faz sua compra onde ela está acostumada. Portanto, esse momento é o **momento de conquista de um cliente**, não para essa venda (no aqui e agora), mas é a conquista de um cliente por anos.

Então esse é o caso de uma venda muito importante, porque ele vai conquistar um cliente no *long time* velho, por um tempo de vida muito grande, então vale tudo nessa hora.

Muda o **habito** da pessoa, é só você ver pessoas que foram pais ou mães recentemente, elas no momento de desespero, compram fralda onde for, e paninho para limpar bumbum onde for, porque você está no desespero, você não está mais com cabeça para ir ao lugar mais econômico de todos.

Então você criou o hábito naquela pessoa, ela segue aquele hábito, ela compra a fralda onde ela vai comprar o arroz e o feijão, se está lá junto, já compra tudo e bora para frente, mesmo que não seja o melhor lugar.

Realmente, no fim das contas é vender mais, mas é conquistar a super longo prazo, e para isso, eles trouxeram para uma fase que eles perceberam que as pessoas não só compram mais, mas elas viram clientes fiéis daquela loja, uma sacada, uma visão a super longo prazo mesmo.

## O que é Machine Learning? Exemplos

Bem, minha pergunta é, isso é machine learning? O que é machine learning? O que está por trás disso?

A ideia do **machine learning** é, na tradução para o português, o **aprendizado de máquina**, então de alguma maneira a máquina vai olhar os dados, ou seja, o que está acontecendo nesses dados, que podem ser recibos de compras, imagens, etc. Por exemplo, estou no aeroporto e as câmeras do aeroporto estão tirando fotos da parte de fora e, esses dados, que são as imagens, são analisados e detectam pássaros. Essa imagem é de um pássaro ou não é de um pássaro?

Então, o computador olha várias fotos de pássaros, de outros animais e objetos, para ser capaz de decidir se a imagem que aparece na foto é um pássaro ou não. Da mesma forma, a gente só sabe se um pássaro é de fato um pássaro porque já vimos muitos pássaros, assim, sabemos identificá-los e diferenciá-los de outros animais.

Agora o computador aprendeu isso, e vai dizer: “*olha tem um pássaro voando, por favor não decole*”, para o avião tomar cuidado. Então o aprendizado de máquina vem disso, seja de uma maneira **supervisionada**, que eu citei agora, que eu supervisionei o aprendizado, como aconteceu com a gente, quando aprendemos o que era um pássaro - nosso pai falou: “*olha isso aqui é um*

pássaro”, então a gente apontava para o cachorro e falava “*olha o piu-piu*”, ele falava “não, isso daí é o au-au”, e quando era pássaro a gente falava “piu-piu” e ele falava “isso, piu-piu”.

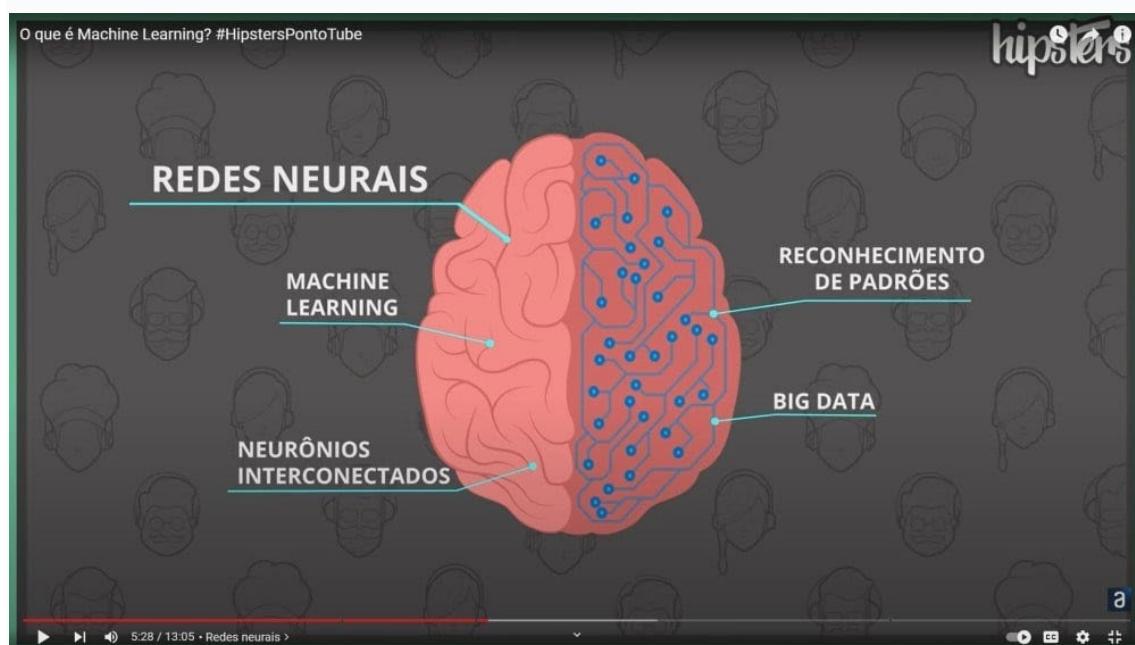
Então, quando o aprendizado é supervisionado, quer dizer que alguém foi ensinando isso para a gente. Mas também tem outras coisas que a gente foi percebendo por **conexões (associações)**. Nossos pais nos ensinaram, por exemplo, o que era uma panela, então, na hora em que a gente via uma frigideira falava “*panela*”, porque é panela, ou seja, a gente juntou coisas parecidas, então **também há outros tipos de aprendizados que não necessariamente são supervisionados**.

E claro, é um tipo de classificação que eu tô fazendo, **tem vários tipos de organização desses algoritmos que aprendem com os dados**.

*Desafios em Machine Learning – Hipsters #137*

## O que são redes neurais?

E onde é que aparecem as tais das **redes neurais**? Tem esse desenho bonitinho de neurônios, camadas, as ligações entre os neurônios, outros neurônios passando as sinapses, mudando os pesos... A gente sempre lê essa história, tem um monte de post e vídeo para leigos, mas **o que isso tem a ver com o cérebro e como é que funciona?**



Alguns são IFS, outras coisas são mais complexas...

Todos vão ser mais complexos, nesse caso, mas não deixa de ser multiplicação e soma, o básico é vezes (x) e mais (+), entram coisas mais complexas depois, mas o básico é isso, são feitas várias contas de vezes e contas de mais, e cada uma dessas toma uma decisão. Por exemplo, na imagem: “ah, eu acho que isso parece uma asinha”, “acho que isso parece um bico”, “isso parece um rabo”, “esse parece uma asa batendo”, “isso parece ser tal coisa”. “Isso parece com as cores de um pássaro”.

Após assimilar as cores de um pássaro ou um padrão de um pássaro, várias coisas podem acabar se **especializando em características daquilo que você está analisando**, podem, mas não necessariamente vão.

Temos essa **primeira camada** de várias coisas tentando aprender características aleatórias, assim como a gente. Se eu percebo que aquilo é uma câmera, é porque eu olho e tem algo que parece uma lente, tem outra parte que parece ser uma capinha, tem algo que parece um flash e tem um objeto que parece um tripé, que é da cor preta, tem vários cabos saindo, etc. Então com isso tudo, a gente chega à conclusão de que é uma câmera, e não é uma cartolina com a foto de uma câmera.

Então da mesma forma, eles vão aprendendo algumas coisas mas não tomam a decisão logo de cara, você cria uma **segunda camada** que vão pegar as informações dessa primeira e tomar uma decisão. Também é possível inserir uma **terceira camada**, por exemplo, uma camada final, que vai pegar todas essas **informações** anteriores e falar “sim, é um pássaro”, “sim, essa empresa vai quebrar no ano que vem”, ou a decisão que for, se for uma decisão de classificação, como sim ou não, ou se for uma estimativa de preço de um apartamento, que é uma regressão. Independente do tipo de conclusão que você quer chegar, nesses **algoritmos** que estou citando, você tem **várias camadas que formam uma rede** chamada de **rede neural**.

*Redes Neurais – Hipsters #165*

## **Redes Neurais – Hipsters #165**

E nessa rede, cada aresta vai tendo um peso mais forte ou mais fraco de acordo com a forma que eu vou treinando e falando: “olha, isso aqui é um pássaro, isso aqui não é um pássaro”.

*Redes Neurais: Por que são tão poderosas? | #AluraMais*

Isso, você vai ter essa rede, composta basicamente por multiplicações e somas, e quando você passa a foto de um pássaro por toda essa **camada**, ela vai se adaptando, vai **adaptando os números** dela, porque ela começa literalmente com números aleatórios. Você passa uma foto de um pássaro, chega no final e ela fala que não é um pássaro, então ela errou, o que ela faz? Ela se adapta, assim como nós.

Depois, é passada outra foto que não é um pássaro e, **baseado nesses números novos**, tenta uma **estimativa nova**. Você vai passando diversas fotos, várias vezes, a mesma foto, assim como vimos várias vezes o mesmo “au-au” (cachorro), várias vezes o mesmo pássaro, até que distingue o que é um pássaro do que é um “au-au” (cachorro), é a mesma coisa que acontece com os algoritmos.

É assim que os sentinelas do Matrix vão atrás dos seres humanos!  
*Matrix: as máquinas vão vencer? Hipsters Ponto Tech #283*

## **Matrix: as máquinas vão vencer? – Hipsters Ponto Tech #283**

### **O que é deep learning?**

Uma coisa que me deixa curioso são aqueles jogos que o Google ou outras empresas ganham, né! Então, tinha o **Deep Blue da IBM** no xadrez e o **Alfa Go do Google** que, pelo que eu entendo, eles **aprenderam a jogar esses jogos complexos** analisando os jogos de outras pessoas e jogando contra outros programas que já jogavam.

Mas aí tem o **Deep learning** que entra e o tal do **Alpha Zero** que, pelo que eu entendo, é ele que vai jogar aquele jogo de xadrez, um jogo de tabuleiro também conhecido como Xadrez Japonês (Shogi), só que contra ele mesmo. Ele sabe quais são as regras, sabe a condição de vitória, mas ele nunca assistiu ninguém jogar.

É como se dois bebês, por exemplo, só soubessem as regras de um jogo, mas nunca viram ninguém jogando, só sabem que podem mover para a esquerda, já para a direita não podem, é impossível, mas eles sabem a condição vencedora. Assim, ficam os dois nenéns, na verdade, um nem só, jogando com ele mesmo, ele dá a volta do outro lado do tabuleiro, joga uma peça aleatória e do outro lado, joga outra peça aleatória e fala: “ah, nessa situação eu venci o jogo. Então, deixa eu olhar para trás e dar pesos para falar

que nesse caminho é interessante, é positivo”, essa é uma forma de **aprender** do nada, de forma **não supervisionada**.

Isso mesmo, a **classificação que eu fiz em supervisionada e não supervisionada** é uma maneira de classificar o mundo, mas existem diversas maneiras.

Essa maneira binária de separar em supervisionado e não supervisionado tem vários problemas, inclusive tem alguns outros que a gente classifica como semi supervisionados, se você ficar pensando nessa polaridade.

Mas independente do **tipo de classificação**, têm maneiras diferentes de fazermos o programa aprender, como você citou anteriormente uma outra. Então nessa outra, imagine que você como ser humano também pode fazer isso, basta lembrar, por exemplo, quando você tinha aula de xadrez na infância com o professor, você tentava mexer o cavalo e ele falava: “*não, veja bem, se você fizer isso vai acontecer a, b e c*”, então ele já cortava alguns caminhos para você já entender como funcionava.

Agora imagine outra situação, em que você não tem esse professor e você faz o papel dos dois lados, você tenta jogar o cavalo, vai para o outro lado e fala: “*hum, agora que aquela pessoa jogou o cavalo para cá, eu vou tentar pegar ela por aqui*”. Nesse caso, é você jogando com você mesmo, e você aprende, não tem problema nenhum.

Só que você vai cometer, provavelmente, no começo, muito mais erros do que com alguém que poderia já ter te dado algumas dicas.

E uma das grandes sacadas é essa, agora alguns dos algoritmos que estão ganhando das pessoas, sejam no Go, no xadrez, no Starcraft, são **algoritmos que aprenderam sozinhos**, só jogando o jogo com elas mesmas.

O que é Deep Learning? #HipstersPontoTube

## Engenharia de Machine Learning e o que se faz nessa profissão

Veja como é escrever e utilizar modelos preditivos, Jupyter notebooks e colocar para rodar num sistema em produção no mundo real, com alimentação a todo momento, autoajustes, autotreinos e muito mais:

Veja por quais trilhas pode seguir seu aprendizado em machine learning, divididas por nível de dificuldade. Você vai encontrar como trabalhar com temas como:

- Aprendizado computacional;
- Sistemas de recomendação;
- Classificação;
- Redes neurais;
- Aprendizado supervisionado e não supervisionado.

E utilizando **ferramentas** como:

- Deep learning;
- SKLearn;
- Python;
- Watson.

Acesse: [Por onde começar os estudos na área de dados?](#)

## **Principais dicas para entrevistas de emprego em Machine Learning**

Confira o vídeo a seguir, e saiba onde é usado o Machine Learning:

*Principais dicas para entrevistas de emprego em Machine Learning | #HipstersPontoTube*

## **Aplicações de Machine Learning**

*3 aplicações de Machine Learning onde você nem imagina com Thiago Santos | #HipstersPontoTube*

## **Machine Learning e o MLOps**

*Machine Learning e o MLOps – Hipsters #171*

Ouvir um pouco de:

## **Machine Learning e o MLOps**

**Confira neste artigo:**

- [Introdução](#)
- [Entenda Machine Learning com um caso real](#)

- O que é Machine Learning? Exemplos
- Como funciona o Machine Learning?
- O que são redes neurais?
- O que é deep learning?
- Engenharia de Machine Learning e o que se faz nessa profissão
- Principais dicas para entrevistas de emprego em Machine Learning
- Aplicações de Machine Learning
- Machine Learning e o MLOps

## Perguntas Frequentes:

### **Qual o objetivo do Machine Learning?**

O objetivo do Machine Learning é desenvolver algoritmos e modelos capazes de aprender a partir de dados e realizar tarefas específicas sem serem explicitamente programados. Ele permite que os computadores automaticamente descubram padrões e façam previsões ou tomem decisões com base nesses padrões.

### **Quais são os tipos de machine learning?**

Existem três tipos principais de Machine Learning: o aprendizado supervisionado, no qual os modelos são treinados com dados rotulados para fazer previsões ou classificações; o aprendizado não supervisionado, em que os modelos encontram padrões nos dados sem rótulos; e o aprendizado por reforço, no qual os modelos aprendem através de tentativa e erro, recebendo recompensas ou penalidades.

### **Qual a diferença entre Inteligência Artificial e Machine Learning?**

A Inteligência Artificial (IA) é um campo mais amplo que abrange diferentes técnicas e abordagens para criar sistemas que podem simular a inteligência humana. Machine Learning, por outro lado, é uma subárea da IA que se concentra em desenvolver algoritmos que permitem que os computadores aprendam com os dados e melhorem seu desempenho ao longo do tempo, sem serem explicitamente programados.

### **Machine Learning e Python: Qual a relação?**

Python é uma das linguagens de programação mais populares para desenvolver soluções de Machine Learning (ML). Ela oferece uma ampla gama de bibliotecas e frameworks, como TensorFlow e scikit-

learn, que simplificam a implementação de algoritmos de Machine Learning. Python é conhecido por sua sintaxe clara e de fácil aprendizado, tornando-o uma escolha comum para os profissionais que trabalham com ML.

### **Deep Learning e Machine Learning: Principais diferenças**

Deep Learning é uma subárea do Machine Learning que se concentra no treinamento de redes neurais profundas para aprender representações hierárquicas de dados. Enquanto o Machine Learning tradicional requer a extração manual de características dos dados, o Deep Learning é capaz de aprender essas características automaticamente. Isso permite que o Deep Learning lide com problemas mais complexos e com grandes volumes de dados, mas também requer mais recursos computacionais e conjuntos de dados de treinamento maiores.

### **O que é deep learning?**

Uma coisa que me deixa curioso são aqueles jogos que o Google ou outras empresas ganham, né! Então, tinha o **Deep Blue da IBM** no xadrez e o **Alfa Go do Google** que, pelo que eu entendo, eles **aprenderam a jogar esses jogos complexos** analisando os jogos de outras pessoas e jogando contra outros programas que já jogavam.

Mas aí tem o **Deep learning** que entra e o tal do **Alpha Zero** que, pelo que eu entendo, é ele que vai jogar aquele jogo de xadrez, um jogo de tabuleiro também conhecido como Xadrez Japonês (Shogi), só que contra ele mesmo. Ele sabe quais são as regras, sabe a condição de vitória, mas ele nunca assistiu ninguém jogar.

É como se dois bebês, por exemplo, só soubessem as regras de um jogo, mas nunca viram ninguém jogando, só sabem que podem mover para a esquerda, já para a direita não podem, é impossível, mas eles sabem a condição vencedora. Assim, ficam os dois nenéns, na verdade, um neném só, jogando com ele mesmo, ele dá a volta do outro lado do tabuleiro, joga uma peça aleatória e do outro lado, joga outra peça aleatória e fala: “ah, nessa situação eu venci o jogo. Então, deixa eu olhar para trás e dar pesos para falar que nesse caminho é interessante, é positivo”, essa é uma forma de **aprender** do nada, de forma **não supervisionada**.

Isso mesmo, a **classificação que eu fiz em supervisionada e não supervisionada** é uma maneira de classificar o mundo, mas existem diversas maneiras.

Essa maneira binária de separar em supervisionado e não supervisionado tem vários problemas, inclusive tem alguns outros que a gente classifica como semi supervisionados, se você ficar pensando nessa polaridade.

Mas independente do **tipo de classificação**, têm maneiras diferentes de fazermos o programa aprender, como você citou anteriormente uma outra. Então nessa outra, imagine que você como ser humano também pode fazer isso, basta lembrar, por exemplo, quando você tinha aula de xadrez na infância com o professor, você tentava mexer o cavalo e ele falava: “*não, veja bem, se você fizer isso vai acontecer a, b e c*”, então ele já cortava alguns caminhos para você já entender como funcionava.

Agora imagine outra situação, em que você não tem esse professor e você faz o papel dos dois lados, você tenta jogar o cavalo, vai para o outro lado e fala: “*hum, agora que aquela pessoa jogou o cavalo para cá, eu vou tentar pegar ela por aqui*”. Nesse caso, é você jogando com você mesmo, e você aprende, não tem problema nenhum.

Só que você vai cometer, provavelmente, no começo, muito mais erros do que com alguém que poderia já ter te dado algumas dicas.

E uma das grandes sacadas é essa, agora alguns dos algoritmos que estão ganhando das pessoas, sejam no Go, no xadrez, no Starcraft, são **algoritmos que aprenderam sozinhos**, só jogando o jogo com elas mesmas.

*O que é Deep Learning? #HipstersPontoTube*

## Engenharia de Machine Learning e o que se faz nessa profissão

Veja como é escrever e utilizar modelos preditivos, Jupyter notebooks e colocar para rodar num sistema em produção no mundo real, com alimentação a todo momento, autoajustes, autotreinos e muito mais:

*Engenharia de machine learning – Hipsters Ponto Tech #248*

Ouvir um pouco de:

**Engenharia de machine learning – Hipsters Ponto Tech #248**

## O que faz uma pessoa engenheira de Machine Learning?

*O que faz uma pessoa engenheira de Machine Learning? com Thiago Santos | #HipstersPontoTube*

## Educação em dados e machine learning

*Educação em Dados e Machine Learning – Hipsters Ponto Tech #301*

Ouvir um pouco de:

### Educação em Dados e Machine Learning – Hipsters Ponto Tech #301

Veja por [quais trilhas pode seguir seu aprendizado em machine learning](#), divididas por nível de dificuldade. Você vai encontrar como trabalhar com temas como:

- Aprendizado computacional;
- Sistemas de recomendação;
- Classificação;
- Redes neurais;
- Aprendizado supervisionado e não supervisionado.

E utilizando **ferramentas** como:

- Deep learning;
- SKLearn;
- [Python](#);
- Watson.

Acesse: [Por onde começar os estudos na área de dados?](#)

## Principais dicas para entrevistas de emprego em Machine Learning

Confira o vídeo a seguir, e saiba onde é usado o Machine Learning:

*Principais dicas para entrevistas de emprego em Machine Learning | #HipstersPontoTube*

## Aplicações de Machine Learning

*3 aplicações de Machine Learning onde você nem imagina com Thiago Santos | #HipstersPontoTube*

## Machine Learning e o MLOps

*Machine Learning e o MLOps – Hipsters #171*

Ouvir um pouco de:

## Machine Learning e o MLOps – Hipsters #171

Confira neste artigo:

- [Introdução](#)
- [Entenda Machine Learning com um caso real](#)
- [O que é Machine Learning? Exemplos](#)
- [Como funciona o Machine Learning?](#)
- [O que são redes neurais?](#)
- [O que é deep learning?](#)
- [Engenharia de Machine Learning e o que se faz nessa profissão](#)
- [Principais dicas para entrevistas de emprego em Machine Learning](#)
- [Aplicações de Machine Learning](#)
- [Machine Learning e o MLOps](#)

**Perguntas Frequentes:**

### **Qual o objetivo do Machine Learning?**

O objetivo do Machine Learning é desenvolver algoritmos e modelos capazes de aprender a partir de dados e realizar tarefas específicas sem serem explicitamente programados. Ele permite que os computadores automaticamente descubram padrões e façam previsões ou tomem decisões com base nesses padrões.

### **Quais são os tipos de machine learning?**

Existem três tipos principais de Machine Learning: o aprendizado supervisionado, no qual os modelos são treinados com dados rotulados para fazer previsões ou classificações; o aprendizado não supervisionado, em que os modelos encontram padrões nos dados sem rótulos; e o aprendizado por reforço, no qual os modelos aprendem através de tentativa e erro, recebendo recompensas ou penalidades.

### **Qual a diferença entre Inteligência Artificial e Machine Learning?**

A Inteligência Artificial (IA) é um campo mais amplo que abrange diferentes técnicas e abordagens para criar sistemas que podem simular a inteligência humana. Machine Learning, por outro lado, é uma subárea da IA que se concentra em desenvolver algoritmos que permitem que os computadores aprendam com os dados e melhorem seu desempenho ao longo do tempo, sem serem explicitamente programados.

### **Machine Learning e Python: Qual a relação?**

Python é uma das linguagens de programação mais populares para desenvolver soluções de Machine Learning (ML). Ela oferece uma ampla gama de bibliotecas e frameworks, como TensorFlow e scikit-learn, que simplificam a implementação de algoritmos de Machine Learning. Python é conhecido por sua sintaxe clara e de fácil aprendizado, tornando-o uma escolha comum para os profissionais que trabalham com ML.

### **Deep Learning e Machine Learning: Principais diferenças**

Deep Learning é uma subárea do Machine Learning que se concentra no treinamento de redes neurais profundas para aprender representações hierárquicas de dados. Enquanto o Machine Learning tradicional requer a extração manual de características dos dados, o Deep Learning é capaz de aprender essas características automaticamente. Isso permite que o Deep Learning lide com problemas mais complexos e com grandes volumes de dados, mas também requer mais recursos computacionais e conjuntos de dados de treinamento maiores.

# Machine Learning: como funciona, benefícios, tipos e exemplos – FIA

Alguém que apresentasse a ideia do **Machine Learning** para as pessoas há algumas décadas provavelmente seria taxado de maluco.

Hoje, ainda que não seja possível comparar a capacidade cognitiva de uma máquina à de um humano, ninguém duvida de mais nada.

Já existem vários exemplos de softwares e equipamentos produzidos pela mão humana que têm algo que podemos chamar, sim, de inteligência.

Mas o maior avanço da inteligência artificial (IA) é permitir que essas máquinas possam se tornar ainda mais espertas – e por conta própria.

Esqueça os cenários pessimistas de obras de ficção científica, nos quais as invenções se voltam contra os humanos e acabam dominando o mundo.

A IA e o Machine Learning são desenvolvidos para o nosso próprio benefício, já que os **robôs não têm muitas de nossas limitações** para desenvolver determinadas tarefas.

Se alimentados por uma **fonte de energia**, eles não precisam dormir, por exemplo.

Além disso, não se desconcentram, não procrastinam, dificilmente erram e desempenham tarefas em velocidade muitas vezes superior à nossa capacidade.

Por isso tudo, podemos concluir que as máquinas permitem uma **produtividade e eficiência muito maior** em qualquer segmento da economia.

Se o Machine Learning ainda é um mundo completamente novo para você, este artigo é uma boa maneira de começar a entendê-lo.

A partir de agora, vamos explicar o conceito de Machine Learning e as aplicações.

Você vai descobrir **como funcionam os algoritmos** de Machine Learning e ver exemplos de uso atual desse processo nas empresas.

Confira só alguns tópicos que vamos abordar no texto:

- O que é Machine Learning (aprendizado de máquina)?
- A evolução do Machine Learning
- Como funciona o Machine Learning?
- Para que serve o Machine Learning (aprendizado de máquina)?
- Qual a importância do Machine Learning?
- Quais os benefícios de usar Machine Learning?
- Quais são os tipos de Machine Learning mais conhecidos?
- Diferentes abordagens e métodos de Machine Learning
- Machine Learning nas empresas
- Onde se usa Machine Learning?
- Diferentes tipos de problemas e tarefas
- Quais são as aplicações do Machine Learning
- Exemplos de Machine Learning: quem está usando?
- Inteligência Artificial e Machine Learning: quais as diferenças?
- Machine Learning e Deep Learning: quais as diferenças?
- Quais as tendências do Machine Learning para o futuro?
- Carreira na área de Machine Learning.

## O Que É Machine Learning (Aprendizado De Máquina)?

Machine learning é **aprendizado de máquina** em inglês.

O nome já entrega bastante coisa, não é mesmo?

Trata-se da capacidade que um equipamento construído pelo homem tem de analisar dados para automatizar a criação de modelos analíticos.

É, portanto, **uma vertente da inteligência artificial**, um conceito mais amplo, que diz respeito à capacidade que uma máquina tem

de tomar decisões a partir de um raciocínio que lembra o pensamento humano.

No caso do Machine Learning, espera-se que essas decisões tomadas pelos equipamentos tenham como base o aprendizado com dados e a identificação de padrões com o mínimo de (ou sem nenhuma) **intervenção humana**.

O Machine Learning nasceu da ideia de que as máquinas podiam aprender a realizar tarefas específicas mesmo sem terem sido programadas para isso.

A grande meta de um desenvolvedor dessa vertente da IA é criar softwares que, ao serem expostos a novos dados, conseguem se adaptar de maneira independente.

Esses dados, somados a **cálculos anteriores** e às vezes submetidos à repetição, produzem decisões e resultados confiáveis.

Apesar de algumas pessoas encararem a inteligência artificial e o aprendizado de máquina como tendências que aproximam os robôs do que há de mais humano e subjetivo em nós, a base de tudo ainda são as Ciências Exatas.

O que permite a uma máquina ter algo parecido com inteligência são os algoritmos, e a seguir falaremos mais sobre eles.

## A Evolução Do Machine Learning

Apesar de estarmos falando de um conceito relativamente novo, a origem do Machine Learning já tem quase **70 anos**.

Na década de 1950, quando os primeiros modelos de computadores eram desenvolvidos, Alan Turing, considerado o

precursor da **informática**, começou a realizar os primeiros testes para analisar o **poder de raciocínio das máquinas**.

Não era nada muito elaborado, mas, para a época, observar os computadores repetindo sequências de comandos já era algo impressionante.

Um pouco mais tarde, utilizando as descobertas de Turing como referência, um cientista de computação norte-americano chamado Arthur Lee Samuel foi além e criou o primeiro **software com capacidade de aprender**.

O experimento consistia em um jogo de damas virtual, em que o sistema ia melhorando a performance à medida em que as partidas passavam.

Ou seja, a máquina se especializava, aprendendo movimentos e **criando estratégias** a partir do seu histórico, e tornava cada vez mais difícil alguém superá-la em uma partida.

Samuel também foi o responsável por usar o termo Machine Learning pela primeira vez, no ano de **1959**.

De lá para cá, a tecnologia evoluiu muito, a quantidade e a complexidade das informações também.

Com isso, novos conceitos e ferramentas também, caso, por exemplo, da **Inteligência Artificial**, do **Big Data**, da **Internet das Coisas**, entre outros.

É difícil prever o que essas novas máquinas serão capazes de fazer no futuro, mas é inegável que elas evoluirão muito e se tornarão cada vez mais **integradas** às nossas rotinas.

## Como Funciona O Machine Learning?

Existem abordagens da inteligência artificial que estudam as estruturas cerebrais, ou seja, o modelo de funcionamento dos neurônios, para criar as máquinas inteligentes.

Mas não se espera, ao menos não nas próximas poucas décadas, que se consiga obter com as máquinas o mesmo resultado que aquele originado por milhões de anos de seleção natural.

Na IA, no Machine Learning e em toda a ciência da computação, os **algoritmos são a base de tudo**.

Eles são sequências de regras e operações que, quando aplicadas a um conjunto de dados, fazem surgir determinado resultado.

Para que seja possível às máquinas aprenderem, os algoritmos são submetidos a determinados métodos, que se dividem em duas abordagens.

A primeira é a **supervisionada**, em que a aprendizagem do algoritmo ocorre porque ele recebe dados que contêm a resposta correta.

Na abordagem **não supervisionada**, por outro lado, os dados que o algoritmo recebe não são rotulados, de modo que os efeitos das variáveis são imprevisíveis.

Essa segunda abordagem, portanto, é mais complexa e avançada, porque nela a própria máquina encontra os padrões desejados e aprimora seus filtros conforme o uso.

## Para Que Serve O Machine Learning (Aprendizado De Máquina)?

Para que serve o Machine Learning (aprendizado de máquina)?

Atualmente, as pesquisas em Machine Learning estão mais vinculadas ao conceito de **indústria 4.0**, também chamada de **Quarta Revolução Industrial**.

Trata-se da era da automação e da tecnologia da informação no setor de serviços e na produção de bens de consumo.

Na realidade, a automação por si só já existe há bastante tempo.

A novidade é o uso de inteligência artificial, Big Data, Internet das Coisas e, é claro, Machine Learning.

Essa nova realidade da automação permitiu um **salto de produtividade** no mundo todo.

Com o Machine Learning, as fábricas estão mais inteligentes, e as máquinas são aprimoradas por conta própria.

No setor de serviços, **robôs substituem os humanos** no atendimento aos clientes.

E não estamos falando dos labirintos no SAC de companhias telefônicas, mas de algoritmos que aprendem com o tempo e suprem cada vez melhor as necessidades de informações dos clientes.

Quando usamos a palavra “robôs”, não se tratam de androides, aqueles com forma humana, ou mesmo de robôs mais “quadrados” mesmo.

Na maioria das vezes, são apenas programas, **conjuntos de códigos** construídos para dar conta de determinada função.

Seja qual for a área, é importante ter em mente que o objetivo não é somente fazer com que os empresários ganhem mais dinheiro.

A qualidade dos produtos e serviços também tende a melhorar com o tempo, porque o aprendizado da máquina é muito mais rápido do que o do humano.

### Qual A Importância Do Machine Learning?

#### Qual a importância do Machine Learning?

O ser humano dá o seu melhor ao realizar tarefas manuais ou intelectuais.

Dentro das nossas possibilidades, fazemos o possível.

O que acontece é que o mundo atual está de tal maneira informatizado que hoje, em um único dia, produz-se mais informações do que em séculos passados inteiros.

Eis o Big Data – é tanta coisa que é **humanamente impossível** aproveitar todos esses dados, e é por isso que recorremos às máquinas.

Quem usa o **aplicativo Waze**, por exemplo, está fornecendo dados sobre a velocidade de deslocamento na via onde se encontra.

A partir dessa informação e dos dados colhidos de usuários que trafegam pela mesma via, o aplicativo irá recomendar ou não que outros motoristas cheguem ao seu destino por aquele mesmo trajeto.

Uma enorme equipe de seres humanos não conseguiria colher esses dados e transformá-los em sugestões de trajetos **em tempo real**.

O algoritmo do aplicativo, que **trabalha 24 horas por dia**, consegue.

Mesmo dessa maneira, com a criação de algoritmos feitos para aproveitar essa imensa quantidade de dados, ainda há muitas informações desperdiçadas.

É para isso que serve o Machine Learning: para que as máquinas possam aprender por conta própria a **processar esses dados** e dar utilidade a eles.

Assim, os softwares e equipamentos construídos pelo homem conseguirão analisar dados cada vez mais complexos e numerosos, de forma automática e rápida.

O resultado será, como destacamos antes, resultados igualmente mais precisos e rápidos, mesmo em grande escala e com **riscos muito menores**.

## Quais Os Benefícios De Usar Machine Learning?

Agora que você já conhece um pouco mais do que é, como funciona e qual a importância do Machine Learning, chegou a hora de entender o que essa **tecnologia** pode acrescentar na prática.

Separamos alguns benefícios para que você possa ter uma noção clara do que o aprendizado de máquina pode trazer de vantagens para a **rotina produtiva de uma empresa**.

Essa vantagem tem tudo a ver com um conceito chamado de iteratividade (assim mesmo, sem o “n”), que significa **aprimorar a partir da repetição** ou do histórico de tentativas.

Ou seja, trata-se da capacidade de aprender de maneira autônoma e entregar respostas que vão se mostrando mais assertivas com o passar do tempo.

Além disso, o Machine Learning, sempre que colocado em contato com novas variáveis, reprograma-se, atualizando as configurações conforme os **dados** recém-chegados.

Sendo assim, a tecnologia está em **evolução permanente**, pois consegue reconhecer os padrões com base nos resultados que já encontrou no passado, e refinar a interpretação, sem a necessidade de uma nova interferência humana.

## Processamento De Dados Ilimitados

Com a quantidade de dados gerados na atualidade, é humanamente impossível **processar** tudo sem o suporte da tecnologia.

O Big Data se vale da Inteligência Artificial e suas respectivas ferramentas, como a Machine Learning, para captar, integrar, analisar e interpretar essas informações.

Graças a essa ajuda, é possível ler conteúdos **em diferentes tamanhos e formatos** e com muito mais rapidez.

É a partir desse processamento que as empresas podem extrair insights para melhorar a **experiência do usuário**.

Afinal, a automatização do gerenciamento de dados permite que informações, como históricos e hábitos dos consumidores sejam processadas e ganhem uma **interpretação mais assertiva**.

## Eficiência

A eficiência **operacional** é uma das principais metas de uma empresa.

Afinal, qual negócio não deseja **diminuir os custos** e, de quebra, **aumentar as receitas?**

Pois o Machine Learning pode ajudar nessa importante missão.

A partir da automatização de certas tarefas burocráticas, é possível **aumentar o nível de assertividade**, uma vez que o erro humano vai quase inexistir.

Ao mesmo tempo, você pode realocar os colaboradores de carne e osso para as atividades intelectuais, que envolvam um poder de **tomada de decisão** maior.

Um exemplo prático de quanto a tecnologia pode melhorar a eficiência de uma empresa é na **manutenção preditiva**.

Quando você consegue antecipar certos problemas, em vez de reparar as consequências depois que eles já ocorrem, economiza **tempo** e dinheiro.

Com Big Data, Inteligência Artificial e Machine Learning, problemas com atualizações de softwares, recalls de maquinários por conta do modelo ou ano de fabricação podem ser resolvidos com **antecedência**.

Até mesmo inconsistências na produção, mostradas pelos dados de alguns sensores, podem ser evitadas.

## Velocidade

Além de processarem uma quantidade ilimitada de **dados**, as tecnologias de IA que envolvem a Machine Learning vão mais além.

Elas conseguem fazer isso e acompanhar a evolução das informações em tempo real ou muito próximo disso.

A velocidade com que essas tecnologias operam é mais um benefício, pois as empresas podem extrair relatos importantes e, instantes depois, usarem esses dados para produzir um conteúdo personalizado dentro do prazo.

## Adaptabilidade

As estratégias e os objetivos de uma empresa **precisam ser maleáveis** para se ajustarem às diferentes variáveis que podem surgir.

Por isso, é muito importante contar com tecnologias que permitam processar dados em tempo real.

Caso algum problema ocorra ou um planejamento se mostre otimista demais, é possível **se adaptar a uma situação** mais próxima da realidade.

Às vezes, não se trata de questões internas, mas da intercorrência de fatores externos, como uma crise econômica ou o desaquecimento do mercado.

Tudo isso pode forçar uma **readequação**, que só poderá ser feita com a rapidez e a assertividade necessárias por quem souber interpretar os indicadores.

# Quais São Os Tipos De Machine Learning Mais Conhecidos?

Assim como acontece com os seres humanos, as máquinas também possuem **diferentes formas de aprendizado**.

A partir de agora vamos falar dos tipos de Machine Learning mais conhecidos.

## Aprendizado Supervisionado

É um modelo em que a máquina recebe um conjunto de dados com rótulos, divididos em **diferentes classificações**.

O aprendizado supervisionado é muito usado para antecipar resultados em que já se tem uma ideia de quais são as **possibilidades de desfecho**, casos de sim ou não, principalmente.

Para verificar se uma transação feita por cartão de crédito é fruto de uma **fraude** ou não, por exemplo.

Isso é possível graças às técnicas de classificação e de regressão aplicadas nesse tipo de ensino.

- **Classificação:** consegue categorizar um dado a partir dos rótulos aprendidos. Por exemplo, um algoritmo já sabe quais são os tipos de cores primárias e secundárias, portanto, quando aparecer algum elemento em vermelho, vai ser colocado entre as cores primárias
- **Régressão:** serve para prever valores contínuos, ou seja, variáveis que tendem a se repetir dentro de uma lógica durante um determinado intervalo de tempo. Por exemplo, o

cálculo de rendimentos para investimentos de taxas pré-fixadas.

## Aprendizado Não Supervisionado

É um modelo em que a máquina recebe uma série de dados que **não possuem rótulos** e, portanto, não há qualquer perspectiva de se prever o resultado final.

Nesses casos, nem os humanos sabem quais informações poderão ser extraídas.

A ideia nesse tipo de aprendizado é justamente reconhecer determinados padrões e, a partir deles, **encontrar uma lógica** entre os dados.

Nesse sentido, o aprendizado não supervisionado utiliza basicamente três técnicas para identificar essas possíveis relações entre as informações:

- **Agrupamento:** busca similaridade entre os dados e os divide em grupos assim que encontra essas semelhanças. Ele pode ser usado, por exemplo, para segmentar o seu público-alvo e favorecer a criação de personas
- **Associação:** combina dois ou mais dados, encontrando uma sequência e identificando padrões. É o caso das recomendações de conteúdo ou das sugestões de compras, entre outros
- **Redução de dimensão:** ajuda a eliminar dados aleatórios, fazendo prevalecer somente aquelas variáveis mais consistentes. Pode ser usado em planos de gerenciamento de riscos, por exemplo, ao reduzir resultados menos prováveis.

## Aprendizado Semissupervisionado

Conforme o nome sugere, é um modelo que funciona como um híbrido dos dois anteriores.

Normalmente, ele é utilizado quando há grande volume de dados, mas **apenas parte dele possui rótulos**, que é a condição que possibilita um aprendizado totalmente supervisionado.

Nesse caso, a máquina e seus algoritmos aprendem tanto a partir de dados supervisionados quanto de não supervisionados.

Em termos práticos, esse método pode ser utilizado para fazer **o reconhecimento facial** de uma pessoa por uma webcam ou pela câmera do smartphone, entre outras aplicações.

## Aprendizado Por Reforço

É um método no qual a máquina aprende através do sistema de tentativas, por **erro e acerto**.

De certa forma, lembra o sistema de recompensas, utilizado na psicologia infantil, para premiar a criança que realiza um comportamento desejado.

No caso do aprendizado da máquina, esse modelo desconsidera um pouco o valor dos dados (rotulados ou não rotulados), e **valoriza mais o ambiente**.

Nesse modelo, existem sempre três variáveis: o agente (a máquina), o meio (lugar onde o agente atua) e as ações (atividades do agente).

Pense no problema como um grande jogo de quebra-cabeças em que é preciso **combinar todas as peças** corretamente.

Sendo assim, a cada peça combinada, a máquina faz um ponto, e a cada associação errada, ela perde.

Ou seja, ela vai aprendendo ao reforçar uma ação, seja ela positiva (acerto) ou negativa (erro), em busca do objetivo final, que é encontrar a melhor estratégia no menor tempo.

## Diferentes Abordagens E Métodos De Machine Learning

### Diferentes abordagens e métodos de Machine Learning

Os métodos estatísticos mais conhecidos e utilizados pelo Machine Learning para processar os dados são **a regressão, a classificação e o clustering**.

Vamos conferir detalhes sobre cada um deles.

#### Régressão

A regressão é utilizada nos algoritmos de aprendizagem supervisionada e permite um **mapeamento das variáveis** da entrada.

O objetivo é determinar suas características para conseguir prever os resultados de saída.

#### Classificação

A classificação, por sua vez, trabalha com respostas com duas ou mais variáveis, permitindo um agrupamento dos **resultados em várias categorias**.

Também é um método que utiliza a aprendizagem supervisionada.

#### Clustering

Já o clustering está entre os métodos que utilizam algoritmos de aprendizagem não supervisionada.

Com ele, é possível **encontrar padrões** em um banco de dados no qual não se pode perceber os efeitos das variáveis.

### Outras Abordagens

Outras abordagens e modelos de aprendizagem podem ser utilizados no Machine Learning, de acordo com os objetivos propostos pelos desenvolvedores, como:

- **Árvores de decisão:** gráfico que apresenta decisões e suas possíveis consequências. É uma forma estruturada, sistemática e lógica de resolução de problemas
- **Classificação bayesiana:** aplica uma fórmula de probabilidade simples com base no Teorema de Bayes
- **Régressão logística:** uma forma estatística capaz de modelar um resultado binomial com variáveis explicativas (uma ou mais).

## Machine Learning Nas Empresas

### Machine Learning nas empresas

A realidade do mercado atual é de **muitos desafios** diante de globalização, avanços tecnológicos e muita instabilidade econômica.

Ao mesmo tempo, o conhecimento é disseminado, e a possibilidade de **empreender**, democratizada.

O resultado é um cenário de maior concorrência e muita dificuldade para se estabelecer no mercado, fazer um nome e prosperar ao longo dos anos.

Qualquer empresa, portanto, tem uma **margem de erro cada vez menor** e, por isso, aproveitar as oportunidades do Machine Learning pode ser o segredo da sustentabilidade do negócio.

Como já destacamos aqui, as máquinas não têm várias limitações dos humanos.

Quando elas conseguem resolver problemas por conta própria, até nossos limites intelectuais são superados.

Os **gestores** que enxergam as oportunidades da IA e do Machine Learning em suas áreas (acredite, elas existem em qualquer segmento) estão um passo à frente.

Se você não sabe por onde começar a adaptação para essa nova realidade, temos uma dica.

Experimente o [\*\*curso de extensão em Análise de Big Data via Machine Learning e Inteligência Artificial\*\*](#) da **FIA (Fundação Instituto de Administração)**.

O curso tem **carga horária de 76 horas** e é destinado a profissionais de diversas áreas que queiram modelar bases de dados com aprendizado de máquina.

Onde Se Usa Machine Learning?

Mostramos algumas aplicações de Machine Learning nas empresas, mas a tecnologia também **pode ser utilizada de outras formas**.

## Combate A Fraudes Em Sistemas De Pagamento

A partir do aprendizado supervisionado, o Machine Learning pode ser utilizado para identificar possíveis **fraudes em cartões de crédito**, por exemplo.

Isso porque o algoritmo leva em conta os hábitos de **consumo** dos usuários, e qualquer tipo de movimentação fora do comum faz com que se acenda **um alerta**.

O banco notifica a bandeira do cartão para não processar a transação até que ela possa ser confirmada pelo portador.

### Tradução De Textos

As traduções automáticas de textos estão **cada vez mais precisas** graças ao Machine Learning.

É só comparar os resultados obtidos hoje em um tradutor como o do Google, por exemplo, com os que eram obtidos alguns anos atrás.

Além de mais corretas, **as traduções estão evoluindo** em contexto e até na percepção de gírias e regionalismos, ficando cada vez menos literais, em todos os idiomas.

### Banco De Dados Autônomo

Conforme mencionamos anteriormente, o Machine Learning possibilita que softwares desempenhem o papel de **gerenciar banco de dados**.

Já os colaboradores humanos podem executar outras atividades mais complexas e criativas.

## Recomendação De Conteúdo

A recomendação de conteúdo é um claro exemplo de aprendizado não supervisionado por associação.

Quando você assiste a alguns filmes e séries de investigação criminal em sequência, a máquina **identifica um padrão** e passa a recomendar **conteúdos semelhantes**.

O mesmo acontece quando uma pessoa pesquisa sobre determinado produto ou serviço e as propagandas seguintes são relacionadas ao objeto da **busca feita anteriormente**.

Você sente como se estivesse sendo vigiado e, de certa forma, está mesmo.

### Diferentes Tipos De Problemas E Tarefas

Diferentes tipos de problemas e tarefas

São várias as funções que softwares e equipamentos com algoritmos de Machine Learning podem desempenhar em uma empresa.

**A inspeção e a revisão** de produtos e componentes em linhas de produção de indústrias é um exemplo.

As máquinas podem aprender a identificar falhas ou futuras falhas nos processos, funcionando quase como um engenheiro de produção.

Os algoritmos também podem reconhecer oportunidades de otimização na produção para o **uso mais eficiente dos recursos** (energia, matéria-prima, etc.).

Essa tarefa, que em alguns casos poderia levar semanas ou meses para os humanos, é feita em tempo real pelas máquinas.

Com menos mão de obra humana e maior capacidade de prever riscos, o Machine Learning também melhora a **segurança do trabalho**, diminuindo o **número de acidentes**, um problema sério em vários segmentos da indústria.

O Machine Learning é capaz ainda de escalar a personalização do **atendimento ao cliente**, uma necessidade muito importante nas empresas que vendem para o consumidor final.

Companhias grandes e globalizadas têm um universo de clientes que pode chegar aos milhões, ou seja, não haveria como atendê-los de forma personalizada com profissionais humanos.

### Quais São As Aplicações Do Machine Learning

#### Quais são as aplicações do Machine Learning

Por enquanto, falamos **principalmente na indústria**, com a automação e a otimização permitindo às máquinas produzirem mais, de maneira mais veloz, eficiente e inteligente.

Mas o Machine Learning pode ser aplicado em diversas outras áreas.

### Carros Autônomos

Você se lembra quando dirigiu um automóvel pela primeira vez?

Hoje pode parecer fácil, mas quando você começou certamente houve alguma dificuldade para fazer o carro andar do jeito certo.

Dirigir bem, afinal, é um processo de aprendizado.

E é por isso que a inteligência artificial e o Machine Learning estão presentes nos **carros autônomos** desenvolvidos por Google, Tesla e Uber.

### Exemplos De Machine Learning: Quem Está Usando?

Agora, chegou o momento de apresentar exemplos práticos de **empresas do mundo todo** que estão usando descobertas na área do Machine Learning para inovar ou melhorar seus processos.

#### General Electric

As máquinas das fábricas da gigante General Electric têm “**gêmeas digitais**”, **réplicas virtuais** dos mesmos equipamentos.

Quando a máquina de verdade apresenta algo como calor acima do normal, vibração, ruído etc., essa informação é coletada por sensores e vai para a nuvem.

A réplica reproduz o funcionamento do equipamento, para prever se a ocorrência poderá acarretar alguma falha e motivar uma manutenção.

#### JPMorgan

O banco americano JPMorgan investe pesado nas pesquisas com Machine Learning – e os investimentos têm valido a pena.

Um algoritmo desenvolvido pela empresa foi **capaz de fazer em segundos o que exigia 360 mil horas** de advogados humanos por ano: interpretar acordos de empréstimo comercial.

#### Walmart

No varejo, algoritmos podem ser desenvolvidos a procurar constantemente oportunidades de **aumentar o ticket médio** por cliente.

Um exemplo é o Walmart, que, por meio do Machine Learning, descobriu que os americanos que compram fraldas no supermercado tendem a levar também cervejas.

Eis uma associação que dificilmente um humano perceberia.

O supermercado acabou colocando os dois produtos no mesmo corredor, conseguindo **vender mais**.

## Google

Possivelmente você chegou a esse texto graças às tecnologias de inteligência artificial e Machine Learning da Google.

Os algoritmos de seu **sistema de busca** são desenvolvidos para reconhecer com precisão quais são as páginas que melhor respondem às dúvidas dos usuários para exibi-las entre os primeiros resultados.

## IBM

A americana IBM desenvolveu o revolucionário Watson, uma **plataforma de serviços cognitivos**.

O sistema Watson tem sido muito usado na área da saúde, no atendimento a pacientes e no combate a doenças graves.

## Inteligência Artificial E Machine Learning: Quais As Diferenças?

Para entender a diferença entre Inteligência Artificial, Machine Learning e depois Deep Learning é interessante pensar naqueles

gráficos setoriais que aprendemos em matemática, que compara a grandeza/pertencimento de duas ou mais variáveis.

Nesse gráfico, temos **a IA como a esfera maior**, pois ela é um campo da Ciência da Computação que estuda as formas de simulação da inteligência humana.

Dentro da esfera da IA, temos um **círculo menor**, que é da Machine Learning, um subcampo da IA.

Outro exemplo de subcampo da IA seria o Processamento de Linguagem Natural, por exemplo.

Ou seja, podemos dizer que todo aprendizado de máquina conta com uma inteligência artificial, mas existem algumas IAs que trabalham com **outro tipo de tecnologia** que não o ML.

Machine Learning E Deep Learning: Quais As Diferenças?

Seguindo a lógica do gráfico setorial, já sabemos que a maior esfera é a da IA e, dentro dela, está a esfera do ML.

Agora, acrescente a essa demonstração um novo círculo, o da Deep Learning, inscrito dentro do ML.

Isso porque **a DL é um subconjunto** do Machine Learning.

O Deep Learning utiliza redes neurais artificiais muito complexas e ajuda a resolver questões mais elaboradas, por isso a diferenciação.

Quais As Tendências Do Machine Learning Para O Futuro?

O Machine Learning já é uma realidade no universo corporativo, e a tendência é que **cada vez mais empresas invistam** nesse tipo de tecnologia.

Até 2019, 37% das empresas utilizavam alguma solução relacionada ao aprendizado de máquina.

Em 2022, esse número está previsto para crescer ainda mais, chegando a 80% dos avanços relacionados ao ML e à Inteligência Artificial, segundo [relatório da Gartner](#) (em inglês).

Ou seja, estamos falando de **um caminho sem volta**, onde ficar atento a algumas das principais tendências desse [mercado](#) significa sair na frente da concorrência.

Por isso, fique atento ao que está por vir em um futuro próximo:

- Mais soluções de Deep Learning
- Maior integração e dispositivos de Internet das Coisas compatíveis com ML
- Migração do Machine Learning para a nuvem
- Processamento da linguagem natural.

## Carreira Na Área De Machine Learning

Investir em uma [carreira](#) na área de Machine Learning é ter a certeza de que não se trata apenas de uma aposta ou tendência momentânea, mas sim uma [profissão](#) que deve ter **muita demanda ainda pela frente**.

Outra boa notícia é que existem diferentes tipos de especialização que você pode seguir, **sem necessariamente ter uma formação** em Tecnologia da Informação, Ciência da Computação ou Engenharia de Softwares.

Afinal, existem cursos de pós-graduação e MBA na área de gestão que possuem enfoque em Big Data, Business Intelligence, Inteligência Artificial e Machine Learning.

Agora, se a sua ideia é trabalhar com o processamento e a análise de dados, de fato, talvez estas carreiras possam combinar mais com você:

- Cientista de dados
- Engenheiro de ML
- Arquiteto de dados
- Pesquisador de ML
- Analista de ML.

## Machine Learning

Não é preciso ser um programador ou gestor da área de TI para descobrir mais sobre a inteligência artificial e as possibilidades trazidas pelos algoritmos de Machine Learning.

A cada minuto que passa, o mundo fica mais tecnológico, e as novidades são adotadas primeiro em **empresas inovadoras**, que enxergam suas **vantagens competitivas**.

Mesmo que as máquinas substituam uma grande quantidade de funções que hoje são ocupadas por seres humanos, ainda será necessário ter pessoas de visão, que saibam reconhecer as melhores oportunidades para explorar os benefícios da tecnologia.

Para desenvolver plenamente essa capacidade, é necessário **compreender pelo menos o básico do funcionamento dos algoritmos**.

Você até pode não ser a pessoa responsável por desenvolvê-los, mas conseguirá reconhecer as brechas, os pontos em que a empresa tem o potencial para se tornar mais eficiente com o Machine Learning.

Então, em vez de lamentar esse cenário e encará-lo como uma “desumanização” das empresas, pense de outra maneira.

Será que não se trata justamente do contrário, ou seja, de **humanizar as máquinas** tanto quanto possível e abrir caminho para explorar nossas características ainda mais humanas, que robô nenhum pode imitar?

Para entender melhor os desafios e oportunidades do Machine Learning, inscreva-se no curso de extensão em [Análise de Big Data via Machine Learning e Inteligência Artificial](#) da FIA Business School.

---

## Portfólio de dados do AWS Health

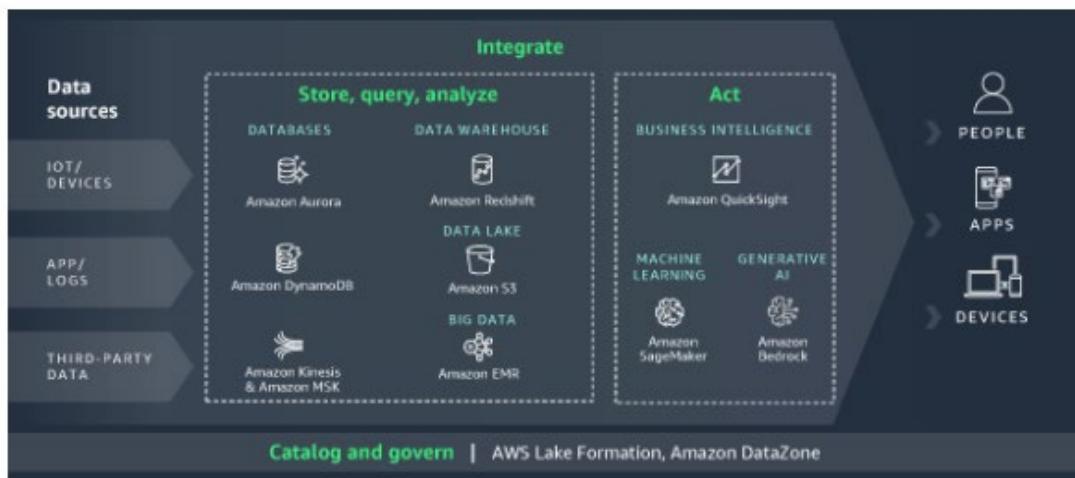
Acelere o acesso e os insights de seus dados próprios, de terceiros e multimodais com o conjunto mais abrangente de recursos de dados e o conjunto mais aprofundado de serviços de inteligência artificial (IA) e machine learning (ML).

**Descubra todo o potencial de seus dados de saúde e ciências biológicas com a AWS**

As organizações dos setores altamente regulamentados de saúde e ciências biológicas (como biofarmacêuticas, HealthTechs, prestadores de serviço e pagadores) precisam acelerar o tempo de diagnóstico e insights, aumentar o ritmo da inovação e trazer terapias diferenciadas ao mercado mais rapidamente com uma estratégia de dados completa.

A AWS fornece um hub centralizado para inovação e colaboração em nível global, conectando você aos dados e às ferramentas de machine learning necessárias e a parceiros confiáveis, ao mesmo tempo em que mantém a proteção e a privacidade de dados de saúde e ciências biológicas.

O portfólio de dados do AWS Health alinha os serviços da AWS com propósito específico e as soluções de parceiros da AWS às necessidades de negócios, desde a transferência, a agregação e o armazenamento seguros de dados até a análise, colaboração, compartilhamento e governança de dados. Com IA generativa e serviços de machine learning com propósito específico, é possível integrar facilmente as tecnologias de ponta aos seus fluxos de trabalho atuais para acelerar as inovações e impulsionar novas descobertas.



*Saiba por que nove das dez maiores empresas farmacêuticas globais usam a AWS para análise e ML.*

**Melhores resultados para os negócios e para os pacientes por meio de dados**

A AWS ajuda organizações de saúde e ciências biológicas a armazenar, transformar, acessar e analisar vários tipos e modos de dados, otimizando a descoberta de medicamentos, a prevenção de doenças, o diagnóstico e o tratamento.

#### Insights mais profundos

Receba visualizações longitudinais e de 360 graus das jornadas do paciente, do produto e do cliente.

#### Aumente a produtividade e a eficiência

Aumente a produtividade e a eficiência por meio da automação integrada de tarefas rotineiras.

#### Acelere o tempo de resposta

Mais rapidez na geração de insights e evidências rotineiras.

#### Acelere o tempo de resposta

Mais rapidez na geração de insights e evidências.

#### Segurança e conformidade

Colaborações de dados de várias partes federados e protegidos para pesquisa.

#### Utilize IA generativa

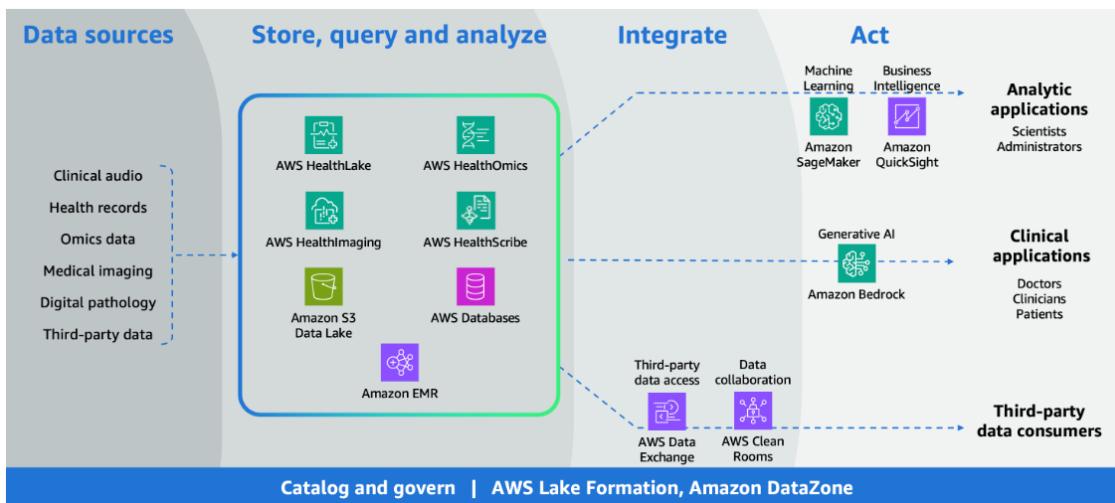
Acesse com mais facilidade e personalize com segurança os modelos básicos corretos enquanto protege os dados.

#### Uso responsável de IA

Promova a confiança e incentive o uso seguro de IA em ambientes clínicos

#### Serviços da AWS

O portfólio de dados do AWS Health conta com os serviços da AWS com propósito específico que ajudam a inovar com mais rapidez e melhorar os resultados dos pacientes.



## [AWS HealthLake](#)

Forneça uma visualização completa dos dados de saúde de indivíduos ou de populações de pacientes.

## [AWS HealthOmics](#)

Transforme dados genômicos, transcriptônicos e outros dados ômicos em insights.

## [AWS HealthImaging](#)

Armazene, transforme e analise imagens médicas na nuvem em uma escala de petabytes.

## [AWS HealthScribe](#)

Gere anotações médicas automaticamente analisando conversas entre pacientes e médicos em suas aplicações.

## [Amazon Bedrock](#)

A maneira mais fácil de criar e escalar aplicações de IA generativa com modelos de base (FMs).

### [\*\*Amazon SageMaker\*\*](#)

Crie, treine e implante modelos de ML com mais rapidez.

### [\*\*Amazon Comprehend Medical\*\*](#)

Entenda o contexto médico usando processamento de linguagem natural

### [\*\*Amazon Transcribe Medical\*\*](#)

Converta automaticamente a fala médica em texto.

### [\*\*Amazon DataZone\*\*](#)

Descubra, compartilhe e administre dados em escala, além dos limites organizacionais alinhados a uma base de data mesh.

### [\*\*AWS Clean Rooms\*\*](#)

Faça a correspondência, analise e colabore com segurança, sem compartilhar nem revelar conjuntos de dados subjacentes.

### [\*\*AWS Data Exchange\*\*](#)

Encontre, assine e use dados de terceiros com facilidade na nuvem.

### [\*\*Amazon Redshift\*\*](#)

Analise dados estruturados e semiestruturados para oferecer a melhor relação preço/performance.

### [\*\*AWS Glue\*\*](#)

Descubra, prepare e integre todos os seus dados em qualquer escala.

### AWS Lake Formation

Crie, gerencie e proteja data lakes em questão de dias.

### Amazon Athena

Analise, com facilidade e flexibilidade, dados em escala de petabytes onde eles estiverem.

## Amazon Textract

**Extraia automaticamente texto impresso, manuscrito e dados de qualquer documento.**

### **Benefícios do produto**

A AWS oferece o mais completo e abrangente conjunto de serviços de machine learning e infraestrutura em nuvem de suporte, colocando o machine learning ao alcance de todos os desenvolvedores, cientistas de dados e especialistas. Considerada líder no Quadrante Mágico da Gartner de serviços para desenvolvedores de IA na nuvem, a AWS está ajudando dezenas de milhares de clientes a acelerar sua jornada para o machine learning.

#### **Conversão de texto em fala**

Transforme texto em falas realistas.

#### **Conversão de fala em texto**

Adicione capacidades de conversão de texto em fala às aplicações.

#### **Machine learning**

Crie, treine e implante modelos de machine learning com rapidez.

#### **Tradução**

Traduza textos usando um serviço de tradução automática neural.

## Ofertas de produtos gratuitos

Crie soluções de machine learning usando estas ofertas de produtos do nível gratuito da AWS.

PRODUTO	DESCRIÇÃO
<a href="#"><u>Amazon Polly</u></a> Conversão de texto em fala	O Amazon Polly é um serviço que transforma texto em falas realistas, permitindo criar aplicações que falam e desenvolver categorias totalmente novas de produtos compatíveis com fala.
<a href="#"><u>Amazon Transcribe</u></a> Conversão de fala em texto	O Amazon Transcribe usa um processo de aprendizado profundo chamado de automatic speech recognition (ASR – reconhecimento automático de fala) para converter fala em texto com rapidez e precisão.
<a href="#"><u>Amazon SageMaker</u></a> Crie e implante modelos de machine learning	O Amazon SageMaker é um serviço totalmente gerenciado que oferece a todos os desenvolvedores e cientistas de dados a capacidade de criar, treinar e implantar rapidamente modelos de machine learning (ML).
<a href="#"><u>Amazon Textract</u></a> Extraia textos e dados	O Amazon Textract corresponde a um serviço de machine learning (ML) que extrai automaticamente textos impressos ou manuscritos e dados de documentos digitalizados.
<a href="#"><u>Amazon Kendra</u></a> Encontre informações precisas mais rapidamente	O Amazon Kendra é um serviço de pesquisa empresarial inteligente que ajuda você a pesquisar em diferentes repositórios de conteúdos com conectores integrados.

<a href="#"><u>Amazon Personalize</u></a>  Personalize experiências online	O Amazon Personalize permite aos desenvolvedores criar aplicações com a mesma tecnologia de machine learning (ML) usada pela Amazon.com para obter recomendações personalizadas em tempo real.
<a href="#"><u>Amazon Rekognition</u></a>  Análise automatizada de imagens e vídeos	O Amazon Rekognition facilita a adição de análises de imagem e vídeo às suas aplicações usando a tecnologia comprovada e altamente escalável de aprendizado profundo que não exige conhecimentos de machine learning para ser usada. Com o Amazon Rekognition, você pode identificar objetos, pessoas, texto, cenas e atividades em imagens e vídeos, além de detectar qualquer conteúdo inapropriado.
<a href="#"><u>Amazon Lex</u></a>  IA de conversação para chatbots	O Amazon Lex é um serviço para a criação de interfaces de conversa em qualquer aplicação usando voz e texto.
<a href="#"><u>Amazon Comprehend</u></a>  Processamento de linguagem natural	O Amazon Comprehend é um serviço de processamento de linguagem natural (NLP) que usa machine learning para encontrar insights e relações em textos. Nenhuma experiência de machine learning necessária.
<a href="#"><u>Amazon Translate</u></a>  Tradução	O Amazon Translate é um serviço de tradução automática neural que fornece traduções de idiomas com rapidez, alta qualidade e economia.

**Implante vozes humanas de alta qualidade e som natural em dezenas de idiomas**

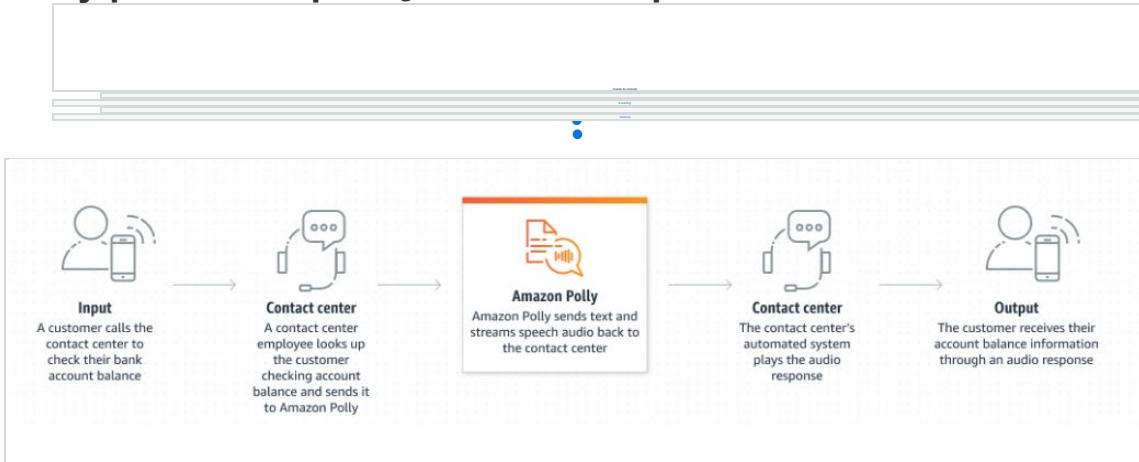
[Comece a usar o Amazon Polly](#)

# Personalize e controle a saída de fala compatível com léxico e etiquetas do Speech Synthesis Markup Language (SSML)

Entregue rapidamente vozes realistas e experiências de usuário conversacionais em tempos de resposta consistentemente rápidos.

## Como funciona

O Amazon Polly usa tecnologias de aprendizado profundo para sintetizar a fala humana com sons naturais, para que você possa converter artigos em fala. Com dezenas de vozes realistas em um amplo conjunto de idiomas, use o Amazon Polly para criar aplicações ativadas por fala.



## Como funciona?

O Amazon Polly usa tecnologias de aprendizado profundo para sintetizar a fala humana com sons naturais, para que você possa converter artigos em fala. Com dezenas de vozes realistas em um amplo conjunto de idiomas, use o Amazon Polly para criar aplicações ativadas por fala.

## Casos de uso

Gere falas em dezenas de línguas

Adicione fala a aplicações com público global como feeds RSS, sites ou vídeos.

## Vozes no Amazon Polly

O Amazon Polly oferece diversas vozes diferentes para você usar. Para ouvir exemplos de vozes, consulte a visão geral do produto Amazon Polly. Para ouvir uma voz específica falar uma amostra fornecida por você, você pode usar o console do Amazon Polly. Para obter instruções, consulte Ouvindo as vozes.

## Vozes disponíveis

O Amazon Polly oferece diversas vozes diferentes em vários idiomas para sintetizar fala a partir de texto. A partir de 2023, o Amazon Polly também tem três vozes en-US de formato longo. Saiba mais sobre vozes de formato longo.

## Interaja com os clientes com uma voz natural

Armazene e reproduza a saída de voz do Amazon Polly para alertar os autores de chamadas por meio de sistemas de resposta de voz interativos ou automatizados.

Uma rede neural que converte uma sequência de fonemas – as unidades mais básicas da linguagem – em uma sequência de espectrogramas, que são instantâneos dos níveis de energia em diferentes bandas de frequência.

Um vocoder, que converte os espectrogramas em um sinal de áudio contínuo.

O primeiro componente do sistema neural TTS é um modelo sequência a sequência. Este modelo não cria seus resultados apenas a partir da entrada correspondente, mas também considera como a sequência dos elementos da entrada funciona em conjunto. O modelo escolhe os espectrogramas que emite para que suas bandas de frequência enfatizem as características acústicas que o cérebro humano usa ao processar a fala.

A saída deste modelo passa então para um vocoder neural. Isso converte os espectrogramas em formas de onda de fala. Quando treinada nos grandes conjuntos de dados usados para construir sistemas de síntese concatenativa de uso geral, essa abordagem sequência a sequência produzirá vozes de maior qualidade e com som mais natural.

The Adriano (italiano), Andrés (espanhol mexicano), Aria (inglês neozelandês), Arlet (catalão), Arthur (inglês britânico), Ayanda (inglês sul-africano), Daniel (alemão), Danielle (inglês americano), Elin (sueco), Gabrielle (francês canadense), Gregory (inglês americano), Hala (árabe, golfo), Hannah (alemão austríaco), Hiujin (cantonês), Ida (norueguês), Isabelle (francês belga), Kajal (hinduí e inglês indiano), Kazuha (japonês), Kevin (inglês americano), Laura

(holandês), Liam (francês canadense), Lisa (holandês belga), Niamh (inglês irlandês), Ola (polonês), Olivia (inglês australiano), Pedro (Inglês americano). espanhol), Rémi (francês), Ruth (inglês americano), Sergio (espanhol castelhano), Sofie (dinamarquês), Stephen (inglês americano), Suvi (finlandês), Thiago (português brasileiro), Tomoko (japonês) e Zayd (As vozes do Golfo Árabe) são suportadas apenas pelo Amazon Polly ao usar NTTS. Todas as outras vozes possuem uma contraparte criada usando o método TTS padrão. Ao usar uma voz somente NTTS, o parâmetro do mecanismo TTS deve ser definido como neural, seja usando o console ou a API.

## Tópicos

Compatibilidade de recursos e regiões

O mecanismo de voz

Vozes Neurais

Estilo de fala do apresentador do NTTS

Os endpoints e os protocolos para essas regiões são idênticos aos usados para vozes padrão. Para obter mais informações, consulte Endpoints e cotas do Amazon Polly.

Os seguintes recursos são suportados para vozes neurais:

Operações de síntese de voz assíncronas e em tempo real.

Estilo de falar do apresentador. Para obter mais informações sobre os estilos de fala, consulte Estilo de fala do apresentador NTTS.

Todos os sinais de fala.

Muitas (mas não todas) tags SSML compatíveis com o Amazon Polly. Para obter mais informações sobre tags SSML compatíveis com NTTS, consulte Tags SSML compatíveis.

Tal como acontece com as vozes padrão, você pode escolher entre várias taxas de amostragem para otimizar a largura de banda e a qualidade de áudio da sua aplicação. As taxas de amostragem válidas para vozes padrão e neurais são 8 kHz, 16 kHz, 22 kHz ou 24 kHz. O padrão para vozes padrão é 22 kHz. O padrão para vozes neurais é 24 kHz. O Amazon Polly oferece suporte aos formatos de fluxo de áudio MP3, OGG (Vorbis) e PCM bruto.

## **Escolhendo o mecanismo de voz (CLI)**

### **Para escolher um mecanismo de voz (CLI)**

O parâmetro do mecanismo é opcional, com três valores possíveis: padrão, Long Form ou Neural. Use esta propriedade ao criar uma operação SynthesisSynthesisTask.

Por exemplo, você pode usar o código a seguir para executar o comando start-speech-synthesis-task da AWS CLI na região Oeste dos EUA-2 (Oregon)

O exemplo da AWS CLI a seguir está formatado para Unix, Linux e macOS. Para Windows, substitua o caractere de continuação Unix de barra invertida (\) no final de cada linha por um sinal de intercalação (^) e use aspas completas ("") ao redor do texto de entrada com aspas simples ('') para tags internas.

Ajuste o estilo de fala, a velocidade da fala, o tom e a intensidade. Use o SSML, uma linguagem de marcação baseada em XML padrão W3C para aplicações de síntese de fala para oferecer suporte a tags SSML.

Comece a usar com uma conta gratuita  
Ofereça melhorias avançadas na qualidade da fala.

Saiba como personalizar o Amazon Polly  
Entenda como usar o Amazon Polly para atender às suas necessidades.

Fale com um especialista  
Aprenda sobre léxicos personalizados, síntese de fala, estilo de fala do apresentador e muito mais.

## AMAZON TRANSCRIBE

Personalize e controle a saída de fala compatível com léxico e etiquetas do Speech Synthesis Markup Language (SSML).

Armazene e redistribua arquivos de fala nos formatos padrão como MP3 e OGG

Entregue rapidamente vozes realistas e experiências de usuário conversacionais em tempos de resposta consistentemente rápidos.

Obtenha insights das conversas com os clientes

Com o [Transcribe Call Analytics](#), é possível extrair insights úteis das conversas de clientes. Os parceiros do [AWS Contact Center Intelligence](#) e o [Contact Lens for Amazon Connect](#) oferecem soluções completas para melhorar o engajamento do cliente, aumentar a produtividade do atendente e fornecer aos supervisores alertas de gerenciamento de qualidade.

## Detecte conteúdo tóxico no áudio

Use o [Transcribe Toxicity Detection](#) para jogos, mídias sociais e outras conversas entre pares. Detecte e categorize áudio tóxico e promova um ambiente on-line seguro e inclusivo.

## Crie legendas e apontamentos de reunião

Use o Amazon Transcribe para intensificar a produtividade e capturar com precisão as reuniões e conversas que são importantes para você. Legende o conteúdo sob demanda e de difusão para aumentar a acessibilidade e melhorar a experiência do cliente.

## Melhore a documentação clínica

Médicos e profissionais de medicina podem usar o Amazon Transcribe Medical para gravar de forma rápida e eficiente as conversas clínicas em sistemas de registro eletrônico de saúde (EHR) para análise. O serviço é qualificado pela HIPAA e treinado para entender a terminologia médica.

Garantir a privacidade e a segurança do cliente é fundamental. Quando necessário, o Transcribe permite mascarar ou remover palavras confidenciais ou inadequadas para o seu público dos resultados da transcrição.

## Filtragem de vocabulário

Você pode especificar uma lista de palavras a serem removidas das transcrições com filtragem de vocabulário. Por exemplo, você pode especificar uma lista de palavras obscenas ou ofensivas e o Amazon Transcribe as removerá das transcrições automaticamente.

Segurança do usuário e segurança recursos de privacidade

Redação automática de conteúdo/redação de PII

Quando instruído, o Amazon Transcribe pode ajudar os clientes a identificar e redigir informações confidenciais de identificação pessoal (PII) das transcrições de idiomas compatíveis. Isso permite

que os contact centers revisem e compartilhem facilmente as transcrições para obter informações sobre a experiência do cliente e treinamento de agentes.

## Proteção de dados

Proteja os dados em repouso usando a chave do Amazon S3 (SSE-S3) ou especifique sua própria chave do AWS Key Management Service. O Amazon Transcribe usa TLS (Transport Layer Security) 1.2, um protocolo criptográfico que permite conexões autenticadas e transporte seguro de dados pela Internet via HTTP, com certificados AWS para criptografar dados em trânsito. Isso inclui transcrições de streaming.

## Detecção de conteúdo de áudio tóxico

O Amazon Transcribe Toxicity Detection usa aprendizado de máquina para manter as conversas de áudio civilizadas e construtivas para incentivar um ambiente on-line seguro e inclusivo. O conteúdo de áudio tóxico é sinalizado em uma das várias categorias para que moderadores humanos identifiquem facilmente e tomem as medidas apropriadas.

## Benefits

AWS and AWS Partner solutions and services help radiologists and health systems manage the fluctuating storage needs of imaging data, applying intelligence to extract insights and personalize patient care.

## Acesse e colabore

Impulsiona uma melhor coordenação de cuidados e decisões de tratamento com integração eficiente, segura e perfeita com imagens médicas e trocas de informações de saúde, acabando com as complexidades e atrasos do sistema

# MEDICAL IMAGE ON AWS

## O poder e a promessa das imagens médicas na nuvem

À medida que a qualidade das imagens médicas avança, as organizações de saúde precisam de acesso a capacidade sob demanda, econômica e escalonável para o armazenamento e arquivamento de petabytes de dados de imagens médicas.

A AWS capacita radiologistas, sistemas de saúde e equipes de pesquisa a aumentar o ritmo da inovação, liberar o potencial dos dados de imagem, desenvolver abordagens mais personalizadas para a prestação de cuidados e melhorar os custos e a eficiência operacional.

A AWS e os parceiros da AWS oferecem serviços e soluções que migram imagens para a nuvem para reduzir custos em meio a necessidades flutuantes de armazenamento, fortalecer a acessibilidade dos dados e facilitar a conformidade – gerando insights mais rápidos e melhor valor. Recursos de segurança e privacidade do usuário

### Análise de chamadas do Amazon Transcribe

Extraia insights de conversa, como sentimento da chamada e volume da fala, para melhorar a produtividade do agente e a experiência do cliente com o

## **Amazon Transcribe Call Analytics.**

Melhore a produtividade do contact center com resumo de chamadas

Gere resumos de chamadas para ajudar os agentes a se concentrarem em fornecer excelentes experiências ao cliente e aumentar a produtividade pós-chamada, capturando automaticamente partes importantes da conversa com o cliente (por exemplo, problemas, resultados ou itens de ação). Os gerentes podem revisar rapidamente esses resumos sem revisar toda a transcrição para compreender o contexto de uma interação e investigar quaisquer problemas do cliente.

Extraia análises detalhadas de chamadas e insights de conversas. Usando o poder do aprendizado de máquina, você pode aplicar rapidamente recursos de processamento de fala para texto e

linguagem natural para descobrir informações valiosas sobre conversas. Você pode então integrar insights como sentimentos de clientes e agentes, problemas detectados e características de fala, como tempo sem conversação, interrupções e velocidade de conversação, em seus aplicativos de análise de chamadas recebidas e efetuadas. Isso pode ajudar seus supervisores a identificar mais facilmente possíveis problemas de clientes, oportunidades de treinamento de agentes e tendências de chamadas.

#### Análise de chamadas do Amazon Transcribe

Melhore a conformidade e o monitoramento com categorização automatizada de chamadas

Monitore suas chamadas em grande escala para monitorar a conformidade com as políticas da empresa ou requisitos regulatórios. Crie e treine suas próprias categorias personalizadas com base em critérios especificados (por exemplo, palavras/frases ou características de conversação). Por exemplo, você pode configurar rótulos de categoria para ver qual porcentagem de chamadas são vendas adicionais ou cancelamento de conta.

#### Produza transcrições de chamadas ricas

Dê aos seus agentes acesso aos detalhes das conversas de interações anteriores.

As transcrições passo a passo fornecem insights como a opinião do cliente, problemas detectados e interrupções.

#### Proteja dados confidenciais de clientes

As conversas geralmente contêm dados confidenciais de clientes, como nomes, endereços, números de cartão de crédito e números de previdência social. Transcribe Call Analytics ajuda os clientes a identificar e redigir essas informações tanto do áudio quanto do texto.

#### Integrações de contact center

**Genesys Cloud CX é uma solução de contact center na nuvem que unifica as experiências dos clientes e dos agentes em vários canais**, como telefone, texto e chat. Você pode transmitir o áudio da sua chamada para o Amazon Transcribe a partir do ambiente Genesys Cloud para melhorar a produtividade do agente e extrair insights de interação com o cliente. Consulte Integração do Genesys Cloud AudioHook para obter mais informações. Além disso, comece a analisar suas chamadas do Genesys Cloud com a solução AWS Live Call Analytics.

## **SDK do Amazon Chime**

O SDK do Amazon Chime é um conjunto de componentes de comunicação em tempo real que os desenvolvedores podem usar para adicionar rapidamente recursos de chamadas de áudio, chamadas de vídeo e compartilhamento de tela a seus próprios aplicativos da Web, móveis ou de telefonia.

## **Conektor de voz do Amazon Chime**

O Amazon Chime Voice Conektor permite integração fácil com contact centers baseados em SIP para gerar transcrições ao vivo atribuídas pelo usuário com o Amazon Transcribe. Consulte a documentação do Amazon Chime Voice Connector para obter mais informações.

## **Amazon Transcribe Médico**

Transcreva facilmente suas conversas médicas com o Transcribe Medical, um serviço de reconhecimento automático de fala (ASR) qualificado para HIPAA.

Modo de ditado

Transcreva com precisão o áudio de um único alto-falante comumente encontrado em casos de uso de ditado médico. Saber mais " Modo conversacional

Transcreva com precisão áudio de conversação com vários alto-falantes composto por médicos e/ou pacientes. Saber mais "

## **Amazon Transcribe Médico - Especialidades médicas**

Transcreva fala em texto em diversas especialidades médicas. API de lote Transcreva arquivos de áudio médicos gravados em grande escala e com alta simultaneidade. Saber mais " API de streaming

**Transcreva fluxos de áudio quase em tempo real** por meio dos protocolos WebSocket Secure ou HTTP/2.

## **Vocabulário personalizado**

Aumente a precisão da transcrição usando vocabulário personalizado para terminologia potencialmente fora do léxico. Identificação do canal

Transcreva simultaneamente áudio multicanal sem custo extra.  
Obtenha uma transcrição final coerente. [Saber mais](#)"  
Diarização de alto-falante  
Discurso separado de diferentes alto-falantes em qualquer canal mono



[Learn more about product pricing](#)

Visit the Amazon Transcribe pricing page.  
[Learn more »](#)

[Sign up for a free account](#)

Instantly get access to the AWS Free Tier.  
[Sign up »](#)

[Start building in the console](#)

Get started building with Amazon Transcribe in the AWS Management Console.  
[Sign in »](#)

## Amazon Transcribe Médico

Transcreva facilmente suas conversas médicas com o Transcribe Medical, um serviço de reconhecimento automático de fala (ASR) qualificado para HIPAA.

### Modo de ditado

Transcreva com precisão o áudio de um único alto-falante comumente encontrado em casos de uso de ditado médico.

### Modo conversacional

Transcreva com precisão áudio de conversação com vários alto-falantes composto por médicos e/ou pacientes.

## Amazon Transcribe Médico - Especialidades médicas

Transcreva fala em texto em diversas especialidades médicas.

### API de lote

Transcreva arquivos de áudio médicos gravados em grande escala e com alta simultaneidade.

### API de streaming

Transcreva fluxos de áudio quase em tempo real por meio dos protocolos WebSocket Secure ou HTTP/2. [Saber mais](#)"

### Vocabulário personalizado

Aumente a precisão da transcrição usando vocabulário personalizado para terminologia potencialmente fora do léxico.

## Custos Reduzidos

Aproveite os recursos de computação sob demanda da nuvem para aumentar ou diminuir a escala com base na necessidade, sem

pagar por hardware local com muitos recursos. Reduza o risco de tempo de inatividade e atenda aos requisitos regulatórios com práticas recomendadas sempre atualizadas integradas na nuvem.

### **Acesse e colabore**

Impulsionone uma melhor coordenação de cuidados e decisões de tratamento com integração eficiente, segura e perfeita com imagens médicas e trocas de informações de saúde, acabando com as complexidades e atrasos do sistema.

### **Melhore e otimize com IA/ML**

Empregue IA/ML para dar suporte à detecção de anomalias que acelera o diagnóstico e melhora os resultados dos pacientes. A automação inteligente otimiza as interações de exibição, aumenta a produtividade, gera receita e melhora a qualidade do atendimento.

### **Casos de uso em destaque**

Os casos de uso a seguir detalham as soluções AWS, AWS Partner e AWS Marketplace disponíveis para cada fluxo de trabalho.

### **O que essas soluções fazem?**

As soluções de armazenamento em nuvem da AWS e de parceiros da AWS liberam os administradores do PACS das tarefas de gerenciamento de infraestrutura de armazenamento. A economia de custos pode ser obtida com o descomissionamento de hardware e data centers relacionados a imagens empresariais, realocando tempo e dinheiro para acelerar projetos que melhorem os resultados dos pacientes.

Os radiologistas se beneficiam da redução do tempo de carregamento de imagens, do processamento acelerado de imagens complexas e de sistemas integrados que permitem a filtragem sofisticada de relatórios de diagnóstico, levando a um melhor atendimento ao paciente.

As soluções de parceiros da AWS também oferecem Vendor Neutral Archives (VNA) e visualizadores universais para imagens médicas armazenadas no VNA em um ambiente seguro, de alto desempenho e econômico. Estas soluções permitem que os dados sejam modificados a montante ou a jusante do VNA. O visualizador universal também pode ser integrado ao prontuário médico eletrônico (EMR) para permitir aos médicos acesso rápido às imagens dos pacientes.

**Visage in the Cloud é um PACS como serviço ultrarrápido e totalmente gerenciado que permite que você entre ao vivo com segurança com escala e desempenho incríveis.** A arquitetura simples do lado do servidor do Visage foi projetada para aproveitar de forma inteligente os melhores recursos de armazenamento em nuvem baseado em objetos, oferecendo desempenho que excede os arrays de armazenamento flash locais tradicionais, usando um dos níveis mais baratos de armazenamento em nuvem criptografado.

Para mais informações, visite o site Visage na Nuvem.

### **Plataforma Visage® 7 para o futuro – impulsionada pela velocidade**

Baixe o whitepaper para obter mais informações sobre os recursos da Visage Enterprise Imaging Platform, incluindo a visualização 3D avançada, o fluxo de trabalho no visualizador, a leitura de fatias finas, a disponibilidade prévia e outros fluxos de trabalho.

### **AWS Summit DC 2021: aproveite a AWS para cargas de trabalho de radiologia**

A UC Health selecionou o Visage como seu visualizador PACS e para executar seu sistema de radiologia de missão crítica na AWS. Nesta sessão, aprenda como aproveitar os melhores recursos da AWS para permitir que os médicos acessem rapidamente imagens com streaming em tempo real.

**O Emergent Connect oferece uma solução de arquivo independente de fornecedor (VNA) com mais de 65 conexões bidirecionais com sistemas de registros médicos eletrônicos (EMR) para total interoperabilidade.** A solução vem equipada com um visualizador de imagens digitais e comunicações em medicina (DICOM) aprovado pela Food and Drug Administration (FDA) que se concentra em fornecer velocidade sem latência. O Emergent Connect também apresenta uma lista de trabalho de modalidade prioritária que conecta PACS e locais diferentes, que por sua vez são integrados com soluções de IA aprovadas pela FDA.

Para obter mais informações, visite as ofertas do Emergent Connect Marketplace.



**Imaging Artificial Intelligence and Machine Learning**

Unlock your medical imaging data to speed diagnosis, fuel innovation, and enable personalized care.

Click to view more information.

## O que essas soluções fazem?

Compreender o contexto do paciente antes de um procedimento diagnóstico é fundamental para um radiologista e para os profissionais de saúde que dependem de diagnósticos de imagens médicas. As soluções da AWS e de parceiros da AWS utilizam IA/ML para otimizar o processo de interpretação de diagnóstico, integrando informações de diferentes sistemas e filtrando e apresentando os dados com base na relevância. As soluções ajudam a melhorar a precisão e a integridade dos relatórios de diagnóstico produzidos, aumentando assim a produtividade dos profissionais de saúde e melhorando o atendimento aos pacientes.

**Na pesquisa, os sistemas PACS e VNA existentes têm capacidades de pesquisa limitadas**, produzindo resultados de pesquisa incompatíveis. Depois de concluir o processo de busca e descoberta, os pesquisadores devem criar cópias de imagens desidentificadas para análise e compilar amostras relevantes, o que pode ser demorado. Finalmente, o processo de formação com as ferramentas de IA existentes para criar um grupo adequado pode ser oneroso. As soluções da AWS e de parceiros da AWS fornecem recursos de pesquisa granular de imagens armazenadas em PACS e VNAs, juntamente com a capacidade de acessar diretamente dados desidentificados do arquivo clínico como parte do processo de treinamento para eliminar o tempo e o custo associados à criação e ao gerenciamento de cópias separadas.



**Multimodal Data Integration**

Tap into the power of multimodal health data to generate insights that advance precision medicine and scientific discoveries.

Click to view more information.

**Com a necessidade de integração de mais de 50 sistemas de imagens médicas diferentes usando os protocolos padrão Digital Imaging and Communications (DICOM) e Health Level Seven (HL7), os departamentos de radiologia precisam facilitar a troca de ressonâncias magnéticas, tomografias computadorizadas, raios X, mamografias e ultrassonografias entre profissionais de saúde. Esta é uma troca eficiente e contínua de imagens médicas e informações de saúde de aceleração de inúmeras fontes para**

permitir uma melhor coordenação de cuidados e decisões de tratamento.

**Com a regra de privacidade da HIPAA** que permite aos indivíduos solicitar e receber legalmente cópias de seus registros médicos, as questões de cuidados de saúde devem cumprir os pedidos de informações de saúde protegidas (PHI), garantindo ao mesmo tempo a confidencialidade e a segurança de seus pacientes. Os mencionados sobre cuidados de saúde podem não ser fornecidos para mover imagens com segurança do Picture Archival and Communication System (PACS) ou do Vendor Neutral Archive (VNA) para um repositório de partilha de imagens de terceiros, ao mesmo tempo que cumprem a aprovação da ITSEC através de gateways seguros.

Com as soluções da AWS e os parceiros da AWS, os provedores de saúde podem armazenar imagens médicas na nuvem e designadas para pacientes e

Ambra Health usa AWS para impulsionar a expansão global da plataforma de imagens médicas  
A Ambra Health usou a AWS para expandir sua plataforma SaaS de dados de imagens médicas para cinco novos países, atender a requisitos rígidos de segurança de dados e expandir seus negócios nacionais. Ambra Health usa AWS para impulsionar a expansão global da plataforma de imagens médicas

O crescimento é a marca registrada da Ambra Health. Desde a sua fundação, o provedor de software como serviço (SaaS) de gerenciamento de dados médicos e imagens cresceu e gerencia mais de cinco bilhões de imagens médicas. Hoje, mais de 425 hospitais, grupos médicos, centros de imagem e trocas de informações de saúde na América do Norte usam a plataforma Ambra Health para melhorar os fluxos de trabalho diários, armazenar imagens médicas e acelerar a prestação de cuidados aos pacientes.

Nos últimos anos, a Ambra Health voltou-se para a expansão internacional. Tornar essa expansão uma realidade, no entanto, foi um grande desafio porque os data centers da Ambra estão todos nos Estados Unidos. “Queríamos acomodar clientes em potencial no Canadá, na Europa e no Japão, mas não tínhamos uma maneira rápida ou econômica de colocá-los em funcionamento”, diz Andrew

Duckworth, vice-presidente de desenvolvimento de negócios da Ambra Health. “Não queríamos ter que construir nossos próprios data centers globalmente e contratar equipes locais para gerenciá-los.” A organização também teve de considerar os rigorosos requisitos de proteção de dados de alguns dos países para os quais pretendia expandir-se. “Os dados de imagens médicas muitas vezes precisam ser armazenados no país ou província que os está adquirindo”, diz Duckworth. “Decidimos que a Nuvem AWS seria a melhor tecnologia para atender às nossas necessidades.”

“Usando a AWS, podemos dimensionar facilmente nossa plataforma de gerenciamento de imagens médicas para atender às necessidades dos clientes de saúde em todo o mundo. Foi muito fácil de implantar e estar operacional globalmente.”

Andrew Duckworth, vice-presidente de desenvolvimento de negócios, Ambra Health

## **O crescimento é a marca registrada da Ambra Health.**

Desde a sua fundação, o provedor de software como serviço (SaaS) de gerenciamento de dados médicos e imagens cresceu e gerencia mais de cinco bilhões de imagens médicas. Hoje, mais de 425 hospitais, grupos médicos, centros de imagem e trocas de informações de saúde na América do Norte usam a plataforma Ambra Health para melhorar os fluxos de trabalho diários, armazenar imagens médicas e acelerar a prestação de cuidados aos pacientes.

## **Alimentando a expansão global**

Ao aproveitar a escalabilidade e o alcance global da AWS, a Ambra Health conseguiu replicar sua infraestrutura local na AWS e expandir a plataforma VNA para novos clientes no Japão, Cingapura, Alemanha e Canadá. “Usando a AWS, podemos dimensionar facilmente nossa plataforma de gerenciamento de imagens médicas para atender às necessidades dos clientes de saúde em todo o mundo. Foi muito fácil implantar e estar operacional globalmente”, afirma Duckworth. “Não tivemos que investir muitos recursos na construção de novos data centers e no treinamento de pessoas para gerenciá-los.”

## **Alimentando a expansão global**

Ao aproveitar a escalabilidade e o alcance global da AWS, a Ambra Health conseguiu replicar sua infraestrutura local na AWS e expandir a plataforma VNA para novos clientes no Japão,

Cingapura, Alemanha e Canadá. “Usando a AWS, podemos dimensionar facilmente nossa plataforma de gerenciamento de imagens médicas para atender às necessidades dos clientes de saúde em todo o mundo. Foi muito fácil implantar e estar operacional globalmente”, afirma Duckworth. “Não tivemos que investir muitos recursos na construção de novos data centers e no treinamento de pessoas para gerenciá-los.”

Por exemplo, a MC Healthcare, um dos maiores distribuidores de cuidados de saúde no Japão, revende a plataforma Ambra Health para hospitais em todo o Japão e agora armazena as suas imagens médicas na AWS. “Anteriormente, nos perguntávamos como poderíamos atender às crescentes necessidades de dados de imagem de uma grande organização como a MC Healthcare. Usando a AWS, isso não é mais um problema”, afirma Duckworth.

## **Alcançando proteção rigorosa de dados**

A Ambra Health pode atender às necessidades regionais de privacidade e proteção de dados de seus clientes, aproveitando os recursos globais da AWS, como a região Ásia-Pacífico (Tóquio) da AWS e os recursos de segurança da AWS, para oferecer suporte à plataforma Ambra Health e manter os dados dos clientes inteiramente dentro do país. . “Segurança e conformidade são os principais requisitos para nossos clientes quando se trata de dados de imagens médicas”, afirma Duckworth. “Podemos atingir esses objetivos contando com o alcance global da AWS e suas fortes certificações de conformidade. Por exemplo, todos os dados de imagem geridos na nossa plataforma pelos nossos clientes no Japão devem ser armazenados nesse país. Sabemos que podemos atender a esse requisito usando a AWS.”

Com base no sucesso de sua expansão global facilitada pela AWS, a Ambra começou recentemente a usar a AWS para expansão dentro dos EUA. “Sentíamos muito confiantes, após nossa expansão global na AWS, que poderíamos fazer o mesmo para novos clientes nacionais, especialmente aqueles que solicitaram fundimos nossa plataforma em seus ambientes AWS existentes”, diz Duckworth.

## **Parceira inicial da APN, Ambra Health**

Ouça Morris Panner, CEO da Ambra Health, parceira inicial da APN e empresa digital de saúde. Morris compartilha suas idéias sobre o

valor de ser um parceiro do APN e por que a experiência no setor das equipes da AWS com as quais ele trabalhou tem sido tão útil.

## **Butterfly Network leva imagens médicas para mais pessoas em mais lugares usando a AWS**

O Butterfly iQ é um dos primeiros sistemas portáteis de ultrassom de corpo inteiro. Com um preço inicial inferior a US\$ 2.000 e uma plataforma inteligente de análise e dados baseada em nuvem, o Butterfly iQ foi projetado para tornar as imagens médicas universalmente acessíveis e acessíveis.

**Butterfly Network leva imagens médicas para mais pessoas em mais lugares usando a AWS**

Sistema portátil de ultrassom de corpo inteiro Butterfly iQ.

O Amazon EFS simplesmente funciona, então podemos nos concentrar na criação de modelos que promovam um melhor atendimento ao paciente.

A Butterfly Network criou um dos primeiros sistemas portáteis de ultrassom de corpo inteiro. Com um preço inicial inferior a US\$ 2.000 e uma plataforma inteligente de análise e dados baseada em nuvem, o Butterfly iQ foi projetado para tornar as imagens médicas universalmente acessíveis e acessíveis.

**Melhorando a tecnologia de ultrassom em todo o mundo**  
**O Butterfly iQ é um dos primeiros sistemas portáteis de ultrassom de corpo inteiro.** Ao tornar as imagens médicas universalmente acessíveis e económicas, a Butterfly está a democratizar os cuidados de saúde. A tecnologia de ultrassom desempenha um papel essencial em todas as condições de saúde humana. Com o Butterfly iQ, a inteligência colectiva da comunidade médica global pode chegar até aos locais mais remotos do planeta, inaugurando uma nova era nos cuidados de saúde.

**A Butterfly reinventou o ultrassom desde o início.** Alimentado por um único chip de silício em um dispositivo portátil conectado a um smartphone, o Butterfly oferece uma experiência personalizada para profissionais de saúde a um custo drasticamente mais baixo – a partir de US\$ 2.000. O Butterfly iQ oferece facilidade de utilização,

aproveitando a inteligência artificial para uma experiência de ultrassom intuitiva. Com uma plataforma de software integrada, o Butterfly fornece uma conexão perfeita para profissionais colaborarem em todo o hospital ou em todo o mundo.

**O Butterfly iQ tem aproximadamente o tamanho de um smartphone e é 80% mais barato que os ultrassons portáteis anteriores. “O Butterfly iQ expande o uso do ultrassom para uma gama mais ampla de contextos clínicos”, afirma Jimmy Jia, principal cientista da Butterfly Network.** “Por exemplo, em salas de emergência, muitas vezes não há tempo para transportar um carrinho de ultrassom tradicional. Mas seria muito viável para todos os médicos de emergência ou enfermeiros terem um scanner Butterfly iQ no bolso.”

### **Melhorando o cuidado com a nuvem AWS**

No entanto, o hardware é apenas parte da imagem. É a inovação do software baseado em nuvem que o torna verdadeiramente único. “Usando os serviços da Nuvem AWS, podemos colocar recursos avançados de geração de imagens nas mãos de muito mais pessoas em todo o mundo e capacitar-las com novas maneiras de armazenar, compartilhar e colaborar com segurança com imagens médicas”, afirma Jia. “Além disso, podemos tornar nossa solução mais inteligente ao longo do tempo, analisando os dados resultantes.”

Para tornar possível esta visão ambiciosa, a Butterfly Network escolheu a Amazon Web Services (AWS) como base tecnológica para a Butterfly Cloud, a sua plataforma de serviços na nuvem. “A AWS sempre foi nossa primeira escolha”, diz Jia. “É um claro líder de mercado devido à sua escalabilidade, inovação e amplitude. Conseguimos obter valor usando cada vez mais serviços à medida que avançamos.”

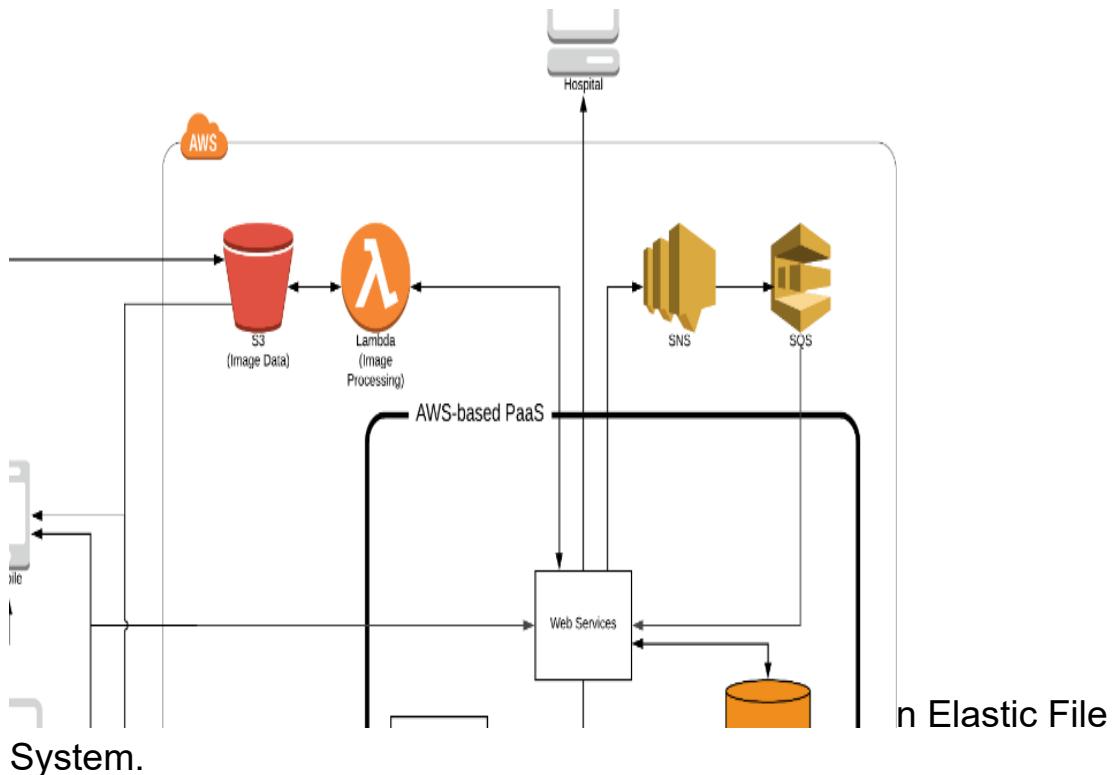
Começando com Amazon Elastic Compute Cloud (Amazon EC2), Amazon Simple Storage Service (Amazon S3) e Amazon Relational Database Service (Amazon RDS), a empresa expandiu seu uso da tecnologia AWS para criar ferramentas clínicas mais ricas e buscar abordagens avançadas de ciência de dados .

Butterfly Network deve cumprir a Lei de Portabilidade e Responsabilidade de Informações de Saúde (HIPAA). Este é outro motivo pelo qual a empresa escolheu a Nuvem AWS: muitos

serviços AWS são elegíveis para HIPAA. Como esses serviços são projetados para ajudar os clientes a atender aos requisitos da HIPAA imediatamente, a Butterfly Network reduziu bastante a complexidade de construir uma arquitetura que estivesse em conformidade com as regulamentações da HIPAA.

Por exemplo, os recursos robustos de registro disponíveis em serviços da AWS qualificados para HIPAA simplificam a captura e a preservação dos logs de acesso necessários, que a Butterfly Network armazena de maneira econômica e segura usando buckets criptografados do Amazon S3. “As soluções AWS são projetadas com recursos para lidar com dados regulamentados, reduzindo significativamente a carga sobre nossos desenvolvedores”, afirma Levy. “A AWS pode celebrar um acordo de parceria comercial HIPAA e simplificar bastante nosso trabalho para alcançar a conformidade.”

Jia observa que esta conformidade é fundamental para a missão da empresa. “Podemos garantir aos clientes que seus dados estão sendo tratados de maneira profissional, segura e compatível”, afirma Jia. “Isso permite o ciclo de feedback positivo do uso desses dados para fornecer melhores serviços.”



## **Butterfly iQ: E se as imagens médicas fossem tão acessíveis quanto um estetoscópio**

Assista ao Dr. John Martin, Diretor Médico da Butterfly Network, demonstrar o dispositivo de imagens médicas Butterfly iQ combinado com a ciência da IA e modelos de aprendizagem profunda treinados na AWS para permitir que usuários com menos treinamento operem o dispositivo de ultrassom e interpretem as imagens capturadas e faça medições mais consistentes.

## **Axial3D: impulsionando a revolução na impressão 3D médica com o Amazon SageMaker**

O Axial3D fornece aos médicos o conhecimento e a confiança necessários para criar um plano cirúrgico na forma de modelos anatômicos 3D específicos do paciente e de alta qualidade. Isto resulta em melhores resultados clínicos para os pacientes, redução significativa do tempo de planejamento e operação e dos custos da cirurgia, e pacientes muito mais bem informados sobre sua condição e a cirurgia proposta.

## **Axial3D: impulsionando a revolução na impressão 3D médica com Amazon SageMaker**

### **Postagem de convidado de Roger Johnston, CEO, Axial3D**

Para os cirurgiões, ter acesso rápido a dados detalhados e confiáveis dos pacientes é vital para o sucesso na sala de operações. Muitas vezes, em casos complexos, a imagem 2D não fornece detalhes ou insights suficientes aos médicos para lhes dar total certeza de sua abordagem nos planos cirúrgicos.

É claro que, na maioria dos casos, as tomografias computadorizadas e as ressonâncias magnéticas proporcionam aos médicos um nível aceitável de percepção para lhes dar confiança para tomar uma decisão e prosseguir com um plano cirúrgico. No entanto – para os três milhões de casos complexos que precisam de ser operados todos os anos, uma digitalização 2D nem sempre é suficiente para planear a cirurgia e comunicar o seu curso de ação ao seu paciente.

**O Axial3D fornece aos médicos o conhecimento e a confiança necessários para criar um plano cirúrgico na forma de modelos anatômicos 3D específicos do paciente e de alta qualidade.**

A impressão 3D padroniza a abordagem na interpretação dos detalhes anatômicos do paciente e elimina a variabilidade desnecessária da interpretação anatômica de um cirurgião para outro. Esses modelos podem ser segurados nas mãos do cirurgião e totalmente examinados – permitindo-lhes criar e praticar um plano cirúrgico antes de colocarem os pés na sala de operações.

“Ser capaz de utilizar um modelo 3D e segurá-lo em suas mãos antes da intervenção cirúrgica é muito esclarecedor para o paciente – ajuda-o a compreender os riscos e benefícios da intervenção cirúrgica”, diz Matthew Lawson, MD, neurocirurgião e Diretor Médico de AVC em Tallahassee Memorial da Saúde. “Demonstrou-se que os modelos 3D aumentam as taxas de consentimento dos pacientes e ajudam na compreensão do paciente sobre o procedimento planejado.”

Atualmente, a tecnologia não ganhou muito terreno fora de uma base central de usuários, muitos dos quais são os primeiros a adotá-la. No entanto, isto irá mudar em breve, graças a inovações que quebram as barreiras para modelos específicos de pacientes, acessíveis e de alta qualidade, em tempos de entrega extremamente rápidos – ou, como gostamos de lhe chamar, a revolução na impressão 3D médica.

### **O Desafio – Compreender as barreiras ao acesso à impressão 3D médica**

A utilização da impressão 3D para criar modelos específicos do paciente para planejamento pré-operatório ainda está em sua infância. Na verdade, o Gartner anunciou recentemente que apenas cerca de 3% dos hospitais e instituições de pesquisa possuem recursos de impressão 3D no local. Mais hospitais estão adotando a tecnologia a cada ano, como por exemplo o novo laboratório de impressão 3D no RVI de Newcastle, mas ainda não está tão difundido quanto poderia ser.

Uma das razões pelas quais a tecnologia não tem sido adotada de forma mais ampla, e muitas vezes vista como um dos maiores gargalos para a produção rotineira de modelos anatômicos

impressos em 3D, é a disponibilidade de radiologistas ou engenheiros biomédicos para segmentar as imagens 2D. O processo de segmentação é o particionamento de uma imagem em múltiplas regiões rotuladas – localizando objetos e áreas de interesse nas imagens. Este pode ser um processo extremamente demorado e afastar os médicos (como os radiologistas) do tratamento dos pacientes durante horas seguidas.

## O objetivo – Remover os gargalos na impressão 3D médica

Com mais de três milhões de procedimentos complexos ocorrendo a cada ano, a automação é essencial para que a impressão 3D se torne uma rotina pré-cirúrgica na área da saúde. O processo de segmentação atualmente leva de 4 a 10 horas por modelo impresso, mas pretendemos reduzir isso através da plataforma AWS e do uso de algoritmos de aprendizado de máquina para aumentar e automatizar o processo de segmentação de imagens 2D e transformá-las em objetos imprimíveis em 3D. Esta combinação permite-nos fornecer resultados quase instantâneos e eliminar os principais gargalos associados à impressão 3D médica.

## A solução – Tornar a impressão 3D uma rotina na área da saúde

Ao utilizar a AWS, a Axial3D está ajudando a transformar a cirurgia, fornecendo insights anteriormente indisponíveis a médicos para planejamento pré-operatório em todo o mundo. Axial3D consegue isso criando modelos impressos em 3D altamente precisos de partes específicas da anatomia do próprio paciente, que permitem aos médicos se prepararem melhor para a cirurgia. Isto resulta em melhores resultados clínicos para os pacientes, redução significativa do tempo de planejamento e operação (e custos) para a cirurgia e pacientes muito mais bem informados sobre sua condição e a cirurgia proposta.

“Certamente, em minha própria prática, com Axial3D criamos uma interface fantástica onde posso clicar em alguns botões e fazer upload de dados de imagens do paciente e eles então entregam o modelo em alguns dias”, diz o Dr. , cirurgião consultor de transplantes do Belfast City Hospital.

Axial3D usa EC2 para hospedar a infraestrutura que permite aos cirurgiões fazer pedidos de forma fácil e rápida para solicitar um

modelo impresso em 3D. Armazenamos as imagens no S3 e gravamos metadados sobre elas no DocumentDB, permitindo-nos rastrear e classificar nossos dados de forma rápida e fácil. Este armazenamento escalável nos permite lidar rapidamente com grandes volumes de imagens médicas, acelerando o processo de criação.



#### AWS Podcast

Subscribe for weekly AWS news and interviews

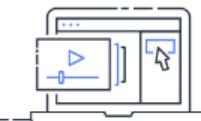
[Learn more »](#)



#### AWS Partner Network

Find an APN member to support your cloud business needs

[Learn more »](#)



#### AWS Training & Certifications

Free digital courses to help you develop your skills

[Learn more »](#)

Axial3D ajuda cirurgiões a salvar vidas com modelos médicos 3D desenvolvidos pela AWS

Leia como o Axial3D ajuda os cirurgiões a salvar vidas usando modelos médicos 3D pré-operatórios detalhados. Usando o Amazon SageMaker, o Amazon EC2 e o Amazon S3, o Axial3D ajudou os cirurgiões do Belfast City Hospital a realizar um transplante de rim com sucesso.

#### Casos de sucesso de clientes com parceiros da AWS

Saiba como clientes de todo o mundo aceleram a adoção da nuvem e estimulam a inovação com a Rede de Parceiros da AWS (APN)

## Anatoscópio cria e transmite avatares 3D a partir de imagens médicas de pacientes

A Anatoscópio, uma startup de tecnologia de saúde, desenvolve soluções de software para criar avatares 3D a partir de imagens médicas de pacientes. A Anatoscópio criou sua própria arquitetura de streaming baseada em Amazon S3, instâncias de GPU EC2 e Docker para garantir a qualidade do serviço e o streaming em tempo real, bem como para garantir a segurança dos dados e ao mesmo tempo controlar os custos de hospedagem.

Leia agora "

Estudo de caso da AWS: Anatoscópio

## **Anatoscópio e streaming de software de alto desempenho**

Criada em 2015, a Anatoscope desenvolve soluções de software para criar avatares 3D a partir de imagens médicas de pacientes. Usando este gêmeo digital, dispositivos e próteses dentárias e ortopédicas podem ser testados virtualmente antes de serem instalados no paciente. Anatoscope é uma startup de tecnologia da saúde que nasceu da pesquisa acadêmica francesa (CNRS Montpellier, INRIA e CHU de Grenoble).

“Trabalhamos na área médica e, como tal, devemos alojar os nossos dados de saúde em servidores HDS seguros. Tínhamos procurado um servidor de dados de saúde credenciado, mas, dado o custo do armazenamento de dados, não era viável. Além disso, queríamos que a nossa solução estivesse disponível via streaming, por isso a qualidade do streaming e a possibilidade de acessá-lo de qualquer lugar do mundo eram essenciais.”

### **Problemas:**

- Tornando software de alto desempenho streamável
- Garantindo a qualidade do serviço e do streaming em tempo real
- Garantindo a segurança dos dados enquanto controla os custos de hospedagem
- Quando a nuvem garante qualidade de streaming
- “A qualidade do nosso streaming é um grande problema”, comenta Frederick Van Meer. “Quando você transmite uma visualização 3D do projeto de um equipamento médico, não pode permitir atrasos. Nosso desafio é conseguir disseminar nosso software para todos de forma muito rápida, sem que os usuários tenham que instalá-lo. Nossa dificuldade é que ele é usado por meio de um navegador da web e não de um aplicativo externo. O número de tecnologias incorporadas é, portanto, limitado.” Desafio superado: “Graças à nossa infraestrutura, podemos transmitir software de alto desempenho, que não requer uma máquina local potente; um simples PC ou tablet é suficiente”.

**A Anatoscópio criou sua própria arquitetura de streaming, baseada no Amazon S3, instâncias de GPU EC2, Docker e um平衡ador de carga.** “Usamos muitas instâncias de GPU porque nossos aplicativos são softwares de design 3D auxiliados por

computador. Eles são implantados em nossos clusters de acordo com a demanda do usuário, quer tenhamos um ou dez, sabendo que um caso pode usar uma instância completa de GPU. A GPU representa 70 a 80% do que fazemos, e a capacidade de resposta da AWS aos picos de demanda de computação foi um fator importante em nossa escolha."

Outro desafio a superar: garantir a segurança dos dados de saúde. A hospedagem de dados de saúde deve atender a requisitos específicos de segurança. "Com o streaming, em primeiro lugar, os dados permanecem sempre no nosso servidor, ou seja, na AWS. Em segundo lugar, quando foram credenciados como HDS, repatriamos nossos dados que estavam com outro host HDS. Os custos de armazenamento eram impensáveis para nós. Começamos com um custo de armazenamento de 55 USD/GB; ao migrar para o Amazon S3, o custo reduziu para 0,023 USD!", observa o COO.

Esta migração permitiu-lhes simplificar a sua organização: "Que confusão! Costumávamos armazenar os dados de identificação do paciente em um host HDS e depois criptografá-los para enviá-los à AWS por um tempo limitado."

Em cinco anos, o Anatoscópio evoluiu em termos de volume, tamanho e atividade. Embora a arquitetura como tal não tenha sido transformada, sua implantação e as ferramentas necessárias mudaram significativamente desde o recrutamento de um DevOps qualificado no uso da AWS. "Fizemos muitas coisas à mão e tínhamos que estar sempre presentes para evitar qualquer problema. Agora economizamos principalmente tempo - para um determinado aplicativo - ao duplicar ambientes (como criar beta ou produzir a partir do trabalho realizado em alfa). Passamos de alguns dias para algumas horas!"

A automação depende de ferramentas externas à AWS, bem como de elementos da arquitetura AWS: VPCs isoladas por clientes/parceiros, construções automatizadas de AMI e imagens implantadas por meio de um LaunchTemplate para suas instâncias de GPU, o gerenciamento dessas instâncias de GPU por meio de um AutoScaling Group, com Lifecycle e Cronograma gerenciado por AWS Lambda e SNS. Nas instâncias API/Web, as implantações automáticas também gerenciam registros DNS no domínio anatoscope.fr via Route 53 e certificados web via ACM.

“A grande vantagem”, observa Frederick Van Meer, “é também podemos duplicar nossa infraestrutura AWS com muita facilidade (principalmente na Europa/Irlanda, atualmente), e com um custo praticamente equivalente, em outras regiões do mundo para atender nossos parceiros ‘ precisa. Por exemplo, um projeto está em andamento nos Estados Unidos.”

### **Um terreno fértil para testes e inovação**

Como membro do programa AWS Activate, a Anatoscope recebeu créditos, que usou para testar sua infraestrutura. “Sem eles, talvez não teríamos testado algumas coisas. Teríamos sido mais cautelosos ao gastar milhares de euros numa solução que poderia não ser a correcta. Ter o suporte da AWS nos ajudou muito nas escolhas técnicas.” Sem falar na “grande facilidade de testar rapidamente conceitos arquitectónicos, e no desempenho das ferramentas para integração das nossas soluções internas”, como outros critérios que promovem os testes.

### **Facilidade de implantação apesar do desafio do bloqueio**

Na verdade, o bloqueio destacou a resiliência das soluções de software oferecidas pelo Anatoscópio. “Os usuários puderam treinar no software remotamente, sem dificuldades, bastando fazer login na plataforma, como se estivessem em suas mesas, pois nosso software é online e não temos problemas de escalar de acordo com a quantidade de usuários”, comenta o COO.

### **Serviços que permitem planejar o futuro com confiança**

“Graças à AWS, conseguimos desenvolver uma infraestrutura em três tipos de software. Na odontologia, o software é utilizado diariamente por diversos protesistas. Na ortopedia, conseguimos assinar com um líder mundial. O próximo passo será abordar a escalabilidade da nossa solução com o aumento do número de usuários. A gestão de big data também faz parte dos nossos desafios futuros: como armazenar um grande volume de dados médicos, a um custo menor, durante os próximos cinco ou dez anos. Nossos casos clínicos têm entre 300 e 400 MB de tamanho e teremos que pensar em uma solução de armazenamento de longo prazo (talvez o Amazon Glacier).”

“No que diz respeito às nossas escolhas técnicas (disponibilizar software de alto desempenho via streaming), percebemos com o COVID-19 que poderíamos chegar a uma solução de fácil acesso.

Como estávamos focados em nossas aplicações ortopédicas e odontológicas, nós nem percebemos. Provamos mais uma vez que nosso software pode ser usado sem dificuldade em qualquer lugar do mundo, em casa, no escritório ou em qualquer outro lugar."

Resumo

### **3 dias para desenvolver o aplicativo de personalização de máscara 3D**

Redução de custos de US\$ 55 para US\$ 0,023/GB de armazenamento com a migração para o Amazon S3

Redução do tempo de alguns dias para algumas horas para duplicar ambientes

Mais sobre o texto originalÉ necessário fornecer o texto original para ver mais informações sobre a tradução

Esta infra-estrutura também facilitou a rápida implantação de novas aplicações. "No contexto da COVID-19, implementámos o AnatoMask, uma solução que permite personalizar uma máscara em 3D no rosto de um utilizador. Ele escaneia seu rosto, envia seus dados e geramos um modelo para uma máscara personalizada imprimível em 3D", explica Frederick Van Meer. A startup adaptou um de seus aplicativos para criação de capacetes para crianças com plagiocefalia. "Desenvolvemos e disponibilizamos em poucos dias, o que teria sido difícil sem os servidores AWS porque o software teria que ser instalado nas instalações dos usuários. Desta forma, basta criar uma conta para eles, e uma clínica pode, por exemplo, criar autonomamente máscaras 3D para os seus funcionários."

O AWS Data Exchange é um componente essencial da estratégia de nuvem financeira da Goldman Sachs porque reduz o atrito para o fornecimento de dados financeiros de fornecedores de terceiros e existentes. Além disso, podemos nos concentrar em fornecer nossos principais serviços e análises de dados diferenciados para melhor atender nossos clientes."

Marco Argenti

Codiretor de Informações da Goldman Sachs

[Leia a história>>](#)

**Histórias de clientes da AWS com Parceiros AWS**  
**Depois de selecionar os filtros, compartilhe sua pesquisa copiando o URL.**

## **Helvetia e Accenture**

Suíça

A Accenture, parceira da AWS, ajudou a Helvetia Insurance, com sede na Suíça, a desenvolver uma estratégia de migração em nuvem para parte do cenário de seus aplicativos para Amazon Web Services (AWS). A Helvetia fornece todas as formas de seguros na Europa e serviços especializados de seguros e resseguros em todo o mundo. Com 72% de seus aplicativos agora migrados para a nuvem, a empresa está prestes a fechar seus data centers até o final de 2023. Usando serviços da AWS, incluindo Amazon EC2 e Amazon RDS, a empresa reduziu suas emissões de carbono em 70% e é capaz de para criar instantaneamente novos ambientes de teste, permitindo que ela se concentre na inovação.

Mais sobre o texto originalÉ necessário fornecer o texto original para ver mais informações sobre a tradução

## **Arity aumenta a adoção do Kafka, melhora a eficiência operacional em 200% e reduz custos em 40% com Lenses.io e Amazon MSK**

### **Sumário executivo**

Arity queria eliminar o custo, a complexidade e a carga operacional do autogerenciamento de clusters Apache Kafka. Trabalhando com o parceiro da AWS Lenses.io, a Arity migrou seus aplicativos de missão crítica para o Amazon Managed Streaming for Apache Kafka (Amazon MSK) totalmente gerenciado. Como resultado, a Arity obteve uma melhoria de 200% na eficiência operacional e uma redução de 40% nas despesas gerais operacionais e nos custos de pessoal. Como parte do projeto, a Arity também implementou soluções adicionais da AWS que melhoraram a segurança, o desempenho e os custos.

### **Impulsionando o futuro do transporte com dados**

Fundada pela The Allstate Corporation em 2016, a Arity é uma empresa de dados e análises de mobilidade que utiliza dados telemáticos para melhor compreender e prever o comportamento de condução. A Arity coleta e analisa dados de condução de mais de 30 milhões de usuários únicos para ajudar companhias de seguros, fabricantes de automóveis, marcas de varejo, municípios e outros a gerenciar riscos e operar com mais segurança.

Para processar o fluxo constante de dados de telemetria em tempo real e fornecer novos serviços aos seus clientes, a Arity confia há muito tempo no Apache Kafka e no AWS Advanced Partner Lenses.io. Lenses.io é líder no desenvolvimento de software que ajuda equipes a simplificar suas operações em tecnologias como Kafka e Kubernetes. A solução Lenses.io oferece uma experiência de desenvolvedor para gerenciar e operar Kafka e fluxos de dados de streaming, permitindo que os engenheiros explorem dados gerados por aplicativos orientados a eventos, monitorem continuamente seu ambiente e identifiquem problemas de desempenho. Lenses.io elimina a complexidade do Kafka, fornecendo uma interface de usuário intuitiva com governança e segurança que torna mais fácil para quase 150 desenvolvedores da Arity adotarem o desenvolvimento de aplicativos de streaming.

No entanto, à medida que a adoção do Kafka e de aplicativos em tempo real pela Arity crescia, tornou-se cada vez mais difícil para a equipe lidar com o custo e a complexidade da infraestrutura autogerenciada do Kafka. Já rodando na Amazon Web Services (AWS), a Arity optou por migrar para o Amazon Managed Streaming for Apache Kafka (Amazon MSK).

kr\_quotemark

Com o Amazon MSK, podemos expandir nossos recursos, adicionar mais armazenamento e memória e adicionar diferentes agentes em minutos, em vez de horas.”

Phil Falkenholm

Diretor de Infraestrutura e Segurança, Arity

Solução totalmente gerenciada elimina a complexidade do Apache Kafka

O Amazon MSK é um serviço Apache Kafka totalmente gerenciado que opera, mantém e dimensiona clusters Kafka. Ao eliminar a carga operacional necessária para provisionar servidores, orquestrar patches e atualizações e planejar eventos de escalabilidade, o Amazon MSK libera equipes técnicas e recursos para se concentrarem no desenvolvimento de aplicações e nos resultados de negócios.

O Amazon MSK se integra perfeitamente ao restante da pilha AWS da Arity, que inclui o Amazon Managed Service for Apache Flink para transformar e analisar dados de streaming e o Amazon Kinesis Data Firehose para processos de extração, transformação e

carregamento (ETL). Os dados são extraídos para processamento no Amazon Simple Storage Service (Amazon S3) e acessados usando Amazon EMR e Amazon Athena.

Para simplificar a migração de seus aplicativos orientados a eventos para o Amazon MSK, a Arity contou com a visibilidade fornecida pelo Lenses.io. “Com o Lenses.io, pudemos explorar os dados gerados pelos aplicativos e ver as principais métricas de desempenho, como a quantidade de dados fluindo por segundo. Isso deu à nossa equipe a confiança de que o Amazon MSK era a escolha certa e que nossos aplicativos poderiam ser migrados”, disse Phil Falkenholm, diretor de infraestrutura e segurança da Arity. A via rápida para o processamento de pico sem perda de dados. Graças ao apoio das equipes Lenses.io e AWS, a Arity migrou três grandes clusters Kafka com centenas de aplicativos e tópicos por cluster para o Amazon MSK em menos de cinco meses.

A equipe de tráfego em tempo real da Arity foi a primeira a concluir a migração e agora está processando com sucesso mais de 5,8 bilhões de geopontos por dia, com uma carga máxima de processamento de 200.000 mensagens por segundo. Outras equipes concluíram ou estão em processo de migração para o Kafka. “Chegar a uma versão de nível superior do Kafka ficou imensamente mais fácil com a migração para o Amazon MSK”, disse Falkenholm. “Foi ótimo ver o trabalho árduo e a dedicação das equipes para concluir essa jornada sem tempo de inatividade ou perda de dados.”

kr\_quotemark

Quer se trate de migração, segurança ou uma nova funcionalidade que

## **Aprendizado de máquina para saúde, ciências biológicas e genômica**

Com o machine learning da AWS, provedores de assistência médica, pagadores, empresas farmacêuticas, startups, ISVs e fornecedores de TI estão melhorando e acelerando diagnósticos, gerenciando a saúde da população, possibilitando a descoberta de medicamentos e modernizando a infraestrutura de atendimento em escala global.

[Saber mais "](#)

## **Parceiros com competência em saúde da AWS**

Os parceiros de competência em saúde da AWS demonstraram conhecimento técnico e sucesso do cliente na criação de soluções de saúde na AWS que armazenam, processam, transmitem e analisam informações clínicas com segurança.

[Saber mais "](#)

Os clientes trabalham com os parceiros de competência em saúde da AWS para criar soluções inovadoras, com custo-benefício e segurança que aumentam a eficácia operacional e clínica, enquanto melhoram os resultados de pacientes para pagadores e fornecedores da área da saúde.

Os parceiros de competência em saúde da AWS apresentaram experiência técnica e foram bem-sucedidos com clientes na criação de soluções da área de saúde na AWS que armazenam, processam, transmitem e analisam com informações de segurança clínicas. Encontre abaixo soluções e ofertas de parceiros da AWS com competência em saúde.

### Sistemas de informações clínicas

Sistemas transacionais são usados no ambiente da prestadora de serviços para detectar e documentar consultas clínicas, bem como disponibilizar atendimento direto a pacientes.

### Análise e saúde populacional

Soluções organizacionais e empresariais para analisar e gerenciar dados populacionais e operacionais, bem como de pacientes e qualidade, para melhorar objetivos de custos e qualidade.

### Administração de saúde

Soluções que contemplam requisitos operacionais de empresas de serviços de saúde, inclusive gerenciamento do ciclo de receitas e ERP.

### Serviços de conformidade

Serviços e soluções que auxiliam as organizações de serviços de saúde com apoio à conformidade e às regulamentações, inclusive arquitetura do sistema.

### Serviços de consultoria

Os parceiros da AWS com competências específicas que oferecem serviços de consultoria já demonstraram ter profundo conhecimento técnico sobre a AWS e sucesso do cliente comprovado em várias áreas especializadas do setor, casos de uso e workload.

### **Aprendizado de máquina para saúde, ciências biológicas e genômica**

Com o aprendizado de máquina da AWS, provedores de assistência médica, pagadores, empresas farmacêuticas, startups, ISVs e fornecedores de TI estão melhorando e acelerando diagnósticos, gerenciando a saúde da população, possibilitando a descoberta de medicamentos e modernizando a infraestrutura de atendimento em todo o mundo

### **Como oferecer suporte à modernização com Cloud PACS por meio do AWS Marketplace**

Junte-se ao Rapid Radiology, ao Steel Valley Portable X-Ray Service e ao AWS Marketplace para saber como o AWS Marketplace pode ajudar a informar sua estratégia de transformação digital e permitir a adoção bem-sucedida de uma solução Cloud PACS.

### **Modernize os arquivos de dados e, ao mesmo tempo, aborde a conformidade, a confiança e a acessibilidade**

Esta sessão aborda os desafios únicos do gerenciamento de dados frios, as diferentes opções para consumir e restaurar seus dados em escala de petabytes e as práticas recomendadas para abordar as principais diretrizes de arquivamento e conformidade.

### **Soluções AWS para assistência médica**

Veja outras soluções de imagens médicas e de saúde visitando a página de soluções do AWS for Healthcare para descobrir casos de uso e soluções em diversas áreas de solução.

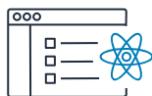
## Additional resources



[Healthcare Case Studies »](#)



[Healthcare Solutions »](#)



[Healthcare Resources »](#)



[Healthcare Blog »](#)

## Melhorando os fluxos de trabalho de imagens médicas com AWS HealthImaging e SageMaker

por Sukhomoy Basak e Hassan Mousaid | em 31 de julho de 2023 | no Amazon SageMaker, Amazon Simple Queue Service (SQS), Amazon Simple Storage Service (S3), Anúncios, Inteligência Artificial | Link permanente | Comentários | Compartilhar  
As imagens médicas desempenham um papel crítico no diagnóstico do paciente e no planejamento do tratamento na área da saúde. No entanto, os prestadores de cuidados de saúde enfrentam vários desafios quando se trata de gerir, armazenar e analisar imagens médicas. O processo pode ser demorado, sujeito a erros e caro.

Há também uma escassez de radiologistas em todas as regiões e sistemas de saúde, fazendo com que a procura por esta especialidade aumente devido ao envelhecimento da população, aos avanços na tecnologia de imagem e à crescente importância do diagnóstico por imagem nos cuidados de saúde.

À medida que a procura por estudos de imagem continua a aumentar, o número limitado de radiologistas disponíveis resulta em atrasos nas consultas disponíveis e nos diagnósticos oportunos. E embora a tecnologia permita melhorias na prestação de cuidados de saúde para médicos e pacientes, os hospitais procuram ferramentas adicionais para resolver os seus desafios mais prementes, incluindo:

### Esgotamento profissional devido à crescente demanda por serviços de imagem e diagnóstico

Tarefas trabalhosas, como medição de volume ou segmentação estrutural de imagens  
Expectativas crescentes dos pacientes que esperam experiências de saúde de alta qualidade que correspondam ao varejo e à tecnologia em termos de conveniência, facilidade e personalização

Para melhorar as experiências dos médicos e dos pacientes, execute seu sistema de comunicação e arquivamento de imagens (PACS) com uma solução em nuvem de imagens de diagnóstico habilitada para inteligência artificial (IA) para obter insights críticos com segurança e melhorar o acesso aos cuidados.

A IA ajuda a reduzir a taxa de esgotamento do radiologista por meio da automação. Por exemplo, a IA economiza tempo de interpretação de radiografias de tórax do radiologista. É também uma ferramenta poderosa para identificar áreas que necessitam de uma inspeção mais detalhada e ajuda a capturar descobertas secundárias que não foram identificadas inicialmente. O avanço da interoperabilidade e da análise proporciona ao radiologista uma visão longitudinal de 360 graus dos registros de saúde dos pacientes para fornecer melhores cuidados de saúde a custos potencialmente mais baixos.

A AWS oferece serviços para enfrentar esses desafios. Esta postagem do blog discute o AWS HealthImaging (AWS AHI) e o Amazon SageMaker e como eles são usados juntos para melhorar os fluxos de trabalho de imagens médicas dos provedores de saúde. Em última análise, isso acelera o diagnóstico por imagem e aumenta a produtividade da radiologia. O AWS AHI permite que os desenvolvedores ofereçam desempenho, segurança e escalabilidade para aplicativos de imagens médicas nativos da nuvem. Ele permite a ingestão de imagens de Digital Imaging and Communication in Medicine (DICOM). O Amazon SageMaker oferece solução completa para IA e machine learning.

Vamos explorar um exemplo de caso de uso envolvendo raios X após um acidente de carro. Neste fluxo de trabalho de diagnóstico por imagem médica, um paciente está na sala de emergência. De lá:

O paciente faz uma radiografia para verificar se há fraturas. As imagens digitalizadas do dispositivo de aquisição fluem para o sistema PACS.

O radiologista revisa as informações coletadas neste procedimento e elabora o relatório.

O fluxo de trabalho do paciente continua à medida que os relatórios são disponibilizados ao médico solicitante.

Soluções e fluxos de trabalho de imagem de última geração  
Os provedores de saúde podem usar o AWS AHI e o Amazon SageMaker juntos para habilitar soluções de imagem de última geração e melhorar os fluxos de trabalho de imagens médicas. A arquitetura a seguir ilustra esse exemplo.

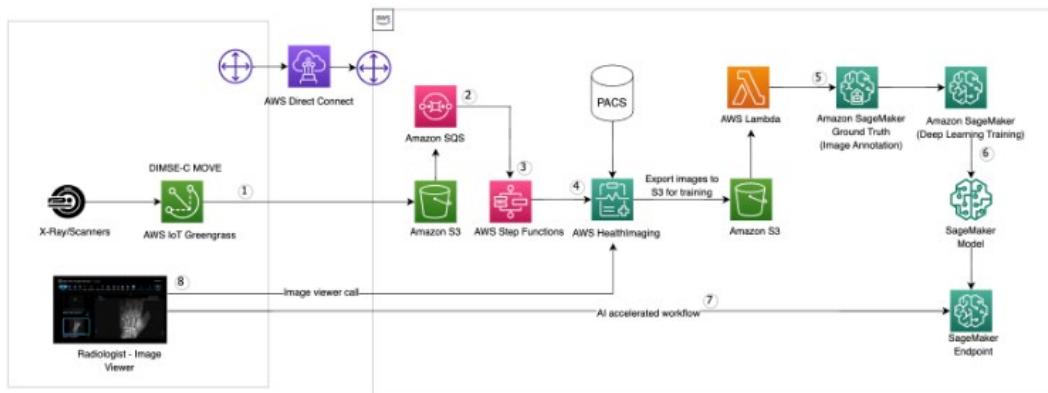


Figura 1: Imagens de raios X são enviadas para o AWS HealthImaging e um endpoint do Amazon SageMaker extraí insights.

## Vamos revisar a arquitetura e os principais componentes:

**1. Scanner de imagem:** captura as imagens do corpo de um paciente. Dependendo da modalidade, pode ser um detector de raios X; uma série de detectores em um tomógrafo; um campo magnético e bobinas de radiofrequência em um scanner de ressonância magnética; ou um transdutor de ultrassom. Este exemplo usa um dispositivo de raios X.

**AWS IoT Greengrass:** tempo de execução de borda e serviço de nuvem configurado com DICOM C-Store SCP que recebe as imagens e as envia para o Amazon Simple Storage Service (Amazon S3). As imagens junto com os metadados relacionados são enviadas para o Amazon S3 e o Amazon Simple Queue Service (Amazon SQS), respectivamente, que acionam o fluxo de trabalho.  
2. Fila de mensagens do Amazon SQS: consome eventos do bucket S3 e aciona uma orquestração de fluxo de trabalho do AWS Step Functions.

**3. O AWS Step Functions** executa os trabalhos de transformação e importação para processar e importar ainda mais as imagens para a instância de armazenamento de dados AWS AHI.

**4. A imagem de diagnóstico final**, juntamente com quaisquer informações e metadados relevantes do paciente, é armazenada no armazenamento de dados AWS AHI. Isso permite a recuperação e o gerenciamento eficientes da data da imagem. Ele também permite o acesso a dados de imagens médicas com latências de recuperação de imagens de menos de um segundo em escala, alimentado por APIs nativas da nuvem e aplicativos de parceiros da AWS.

**5. Os radiologistas responsáveis pela verdade básica das imagens de ML realizam anotações de imagens médicas usando o Amazon SageMaker Ground Truth.** Eles visualizam e rotulam imagens DICOM usando um fluxo de trabalho de rotulagem de dados personalizado – um serviço de rotulagem de dados totalmente gerenciado que oferece suporte a fluxos de trabalho de rotulagem de dados integrados ou personalizados. Eles também utilizam ferramentas como o 3D Slicer para anotações interativas de imagens médicas.

**6. Os cientistas de dados criam ou aproveitam modelos integrados de aprendizagem profunda usando as imagens anotadas no Amazon SageMaker.** O SageMaker oferece uma variedade de opções de implantação que variam desde baixa latência e alto rendimento até trabalhos de inferência de longa duração. Essas opções incluem considerações para inferência em lote, em tempo real ou quase em tempo real.

**7. Os provedores de saúde usam AWS AHI e Amazon SageMaker para executar fluxo de trabalho de detecção e interpretação assistido por IA.** Este fluxo de trabalho é usado para identificar fraturas, luxações ou lesões de tecidos moles difíceis de visualizar, para permitir que cirurgiões e radiologistas tenham mais confiança em suas escolhas de tratamento.

**8. Finalmente, a imagem armazenada no AWS AHI** é exibida em um monitor ou outro dispositivo de saída visual onde pode ser analisada e interpretada por um radiologista ou outro profissional médico.

**O Open Health Imaging Foundation (OHIF) Viewer é uma plataforma de imagens médicas de código aberto, baseada na web. Ele fornece uma estrutura básica para a construção de aplicativos de imagem complexos.**

Radical Imaging ou Arterys são parceiros da AWS que fornecem visualizador de imagens médicas baseado em OHIF.

Cada um desses componentes desempenha um papel crítico no desempenho geral e na precisão do sistema de imagens médicas, bem como na pesquisa e desenvolvimento contínuos focados na melhoria dos resultados diagnósticos e no atendimento ao paciente. O AWS AHI usa codificação de metadados eficiente, compactação sem perdas e acesso a dados com resolução progressiva para fornecer desempenho líder do setor para carregamento de imagens. A codificação eficiente de metadados permite que visualizadores de imagens e algoritmos de IA entendam o conteúdo de um estudo DICOM sem precisar carregar os dados da imagem.

## **Segurança**

O modelo de responsabilidade compartilhada da AWS se aplica à proteção de dados no AWS AHI e no Amazon SageMaker.

**O Amazon SageMaker** é qualificado para HIPAA e pode operar com dados que contenham informações de saúde protegidas (PHI). A criptografia de dados em trânsito é fornecida por SSL/TLS e é usada na comunicação com a interface front-end do Amazon SageMaker (para o notebook) e sempre que o Amazon SageMaker interage com qualquer outro serviço da AWS.

**O AWS AHI** também é um serviço qualificado para HIPAA e fornece controle de acesso no nível de metadados, garantindo que cada usuário e aplicativo possam ver apenas as imagens e os campos de metadados necessários com base em sua função. Isso evita a proliferação de PHI do paciente. Todo o acesso às APIs AWS AHI é registrado detalhadamente no AWS CloudTrail.

Ambos os serviços aproveitam o serviço AWS Key Management (AWS KMS) para satisfazer o requisito de que os dados PHI sejam criptografados em repouso.

## Conclusão

Nesta postagem, revisamos um caso de uso comum para detecção precoce e tratamento de doenças, resultando em melhores resultados para os pacientes. Também abordamos uma arquitetura que pode transformar o campo da radiologia, aproveitando o poder da tecnologia para melhorar a precisão, a eficiência e a acessibilidade das imagens médicas.

Leitura adicional

[Parceiros de imagens da AWS Health](#)

[AWS apresenta AWS HealthImaging na RSNA22](#)

[Anote imagens DICOM e crie um modelo de ML usando a estrutura MONAI no Amazon SageMaker](#)

[Práticas recomendadas de implantação de MLOps para modelo de inferência em tempo real que atende endpoints com Amazon SageMaker](#)

.

## Apresentando o AWS HealthImaging

**Apresentando o AWS HealthImaging** — desenvolvido especificamente para imagens médicas em grande escala por Tehsin Syed e Andy Schuetz | em 25 de julho de 2023 | no Amazon Simple Storage Service (S3), AWS DataSync, AWS Direct Connect, AWS HealthImaging, Saúde, Indústrias | Link permanente | Comentários | Compartilhar

Temos o prazer de anunciar a disponibilidade geral do AWS HealthImaging, um serviço desenvolvido especificamente que ajuda os construtores a desenvolver aplicativos nativos da nuvem que armazenam, analisam e compartilham dados de imagens médicas em escala de petabytes. HealthImaging ingere dados no formato DICOM P10. Ele fornece APIs para recuperação de baixa latência e armazenamento específico.

Nossos clientes do setor de saúde nos dizem que desejam que suas equipes de atendimento tenham os melhores aplicativos de imagens médicas e que desejam reduzir a complexidade do gerenciamento da infraestrutura. Nossos clientes focados em pesquisa desejam analisar dados de imagens em escala e acelerar a colaboração e a descoberta em suas organizações. Ambos os grupos de clientes expressam o desejo de que todos os aplicativos de imagens médicas de suas organizações funcionem a partir do mesmo armazenamento de dados. A nuvem pode ajudar a atender

a essas necessidades dos clientes. Com o HealthImaging, os construtores, como os parceiros da AWS que fornecem aplicativos de imagens médicas e soluções de pesquisa, podem se concentrar mais em enfrentar os desafios desses clientes, em vez de se preocuparem com a infraestrutura.

**Expansão da imagem médica na prestação de cuidados e pesquisa**  
Por mais de 100 anos, os profissionais de saúde têm usado imagens médicas, como raios X, ressonância magnética e ultrassom, para observar o interior dos pacientes de forma não invasiva. A ganhadora do Prêmio Nobel Marie Curie foi uma das pioneiras em imagens médicas. Ela desenvolveu veículos com equipamentos de raios X, chamados “petite Curies”, para ajudar os cirurgiões do campo de batalha a prestarem melhores cuidados durante a Primeira Guerra Mundial. Hoje, as imagens médicas são usadas para diagnosticar e monitorar uma ampla gama de condições de saúde, abrangendo oncologia, trauma, acidente vascular cerebral e muito mais. Globalmente, mais de 3,6 bilhões de procedimentos de imagens médicas são realizados a cada ano, gerando coletivamente exabytes de dados de imagens médicas.

O sistema de saúde está lutando para atender à crescente demanda por procedimentos de imagens médicas. Desde 2008, o número médio de procedimentos de imagem atribuídos a radiologistas nos EUA aumentou de 58 para 100 por dia. Nesse mesmo período, o tamanho típico do estudo de imagem dobrou para quase 150 MB. Como resultado, os radiologistas precisam de novas tecnologias para aumentar a produtividade, e a IA está sendo cada vez mais usada para agilizar fluxos de trabalho cognitivamente exigentes e minimizar erros.

Os grupos de TI dos prestadores de serviços de saúde são frequentemente responsáveis pela infraestrutura que hospeda estudos de imagens médicas novos e arquivados. Essas organizações gerenciam arquivos de imagens em rápido crescimento, normalmente no local. Eles veem a infraestrutura consumindo consideráveis metros quadrados, equipe de TI e orçamentos operacionais. Eles também gerenciam uma variedade crescente de aplicativos empresariais que exigem acesso às mesmas imagens médicas, cada uma com diferentes necessidades de latência e resolução. Isso resulta no armazenamento de várias cópias em cache de cada imagem para vários aplicativos, além de cópias adicionais para armazenamento de longo prazo.

Consequentemente, eles observam custos de armazenamento mais elevados devido à duplicação de dados e à incerteza sobre qual versão de uma imagem é oficial.

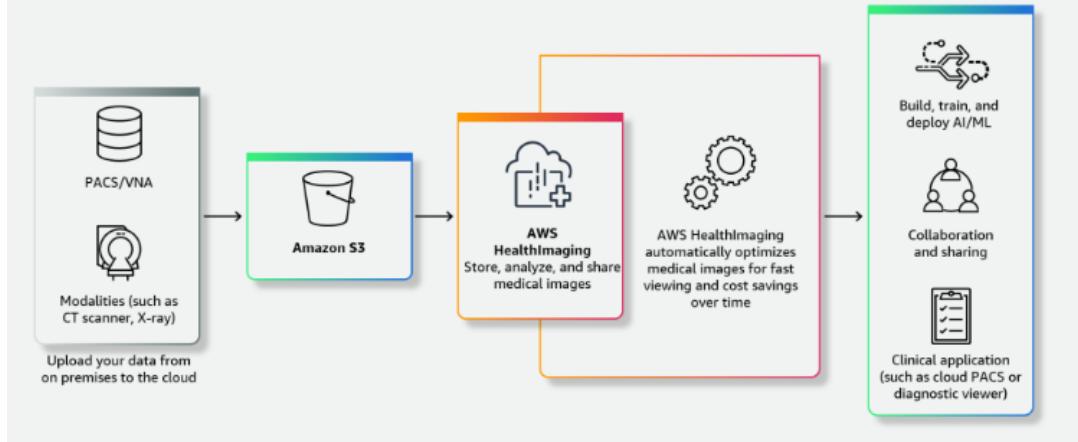
As colaborações entre equipes de cuidados e grupos de investigação podem levar a ainda mais cópias de dados. As equipes de atendimento normalmente exigem dados totalmente identificados, enquanto as equipes que constroem modelos de IA podem preferir usar dados não identificados. Com arquiteturas locais tradicionais, os clientes podem precisar fazer cópias adicionais de dados para cada caso de uso, resultando em custos de armazenamento mais elevados e em maior complexidade operacional. A expansão das imagens médicas criou vastos conjuntos de dados que podem ser usados para desenvolver novos modelos de linguagem e visão computacional de IA. No entanto, os silos de dados legados impedem a inovação, limitando o acesso dos investigadores aos dados.

## **Apresentando o AWS HealthImaging**

HealthImaging fornece um armazenamento de dados de imagens médicas específico que simplifica o provisionamento da infraestrutura, dando aos clientes mais tempo para cuidar dos pacientes e realizar pesquisas. Com o HealthImaging, todos os aplicativos de uma organização podem acessar uma única cópia oficial dos dados sem duplicação, e os usuários podem acessar os dados com segurança de qualquer lugar. Com apenas alguns cliques no console HealthImaging, você pode provisionar um armazenamento de dados capaz de hospedar petabytes de dados de imagens médicas, mantendo cada imagem pronta para recuperação de baixa latência. Além disso, o HealthImaging reduz a quantidade de infraestrutura necessária para operar soluções empresariais de imagem, o que ajuda a economizar custos e reduzir a complexidade operacional.

Os clientes podem usar aplicativos desenvolvidos com base no HealthImaging para aproveitar os baixos custos de armazenamento para arquivos de imagens, sem se preocupar com ciclos de atualização de hardware ou planejamento de capacidade. À medida que novos dados são gerados pelas modalidades de imagem, eles podem ser importados para o HealthImaging e ficar imediatamente disponíveis para recuperação por aplicativos de diagnóstico

## How it works



Os parceiros da AWS estão inovando em nome dos clientes  
Os parceiros da AWS já estão usando o HealthImaging para  
reimaginar as soluções de imagens médicas usadas por  
radiologistas, equipes de atendimento e pesquisadores.

Wake Forest Baptist Health está tornando o conteúdo clínico mais  
acessível aos estudantes de radiologia, com soluções da Apollo  
Enterprise Imaging e HealthImaging.

“Precisamos da capacidade de dimensionar, compartilhar e  
visualizar imagens médicas para pesquisa e educação em toda a  
nossa empresa e com colaboradores em todo o mundo. Trabalhar  
em colaboração com a Apollo EI, usando o AWS HealthImaging e  
suas tecnologias de ponta de repositório de imagens empresariais,  
torna isso possível.” — Josh Tan, gerente de sistemas da Wake  
Forest Baptist Health

A Philips, líder global em imagens médicas, pretende usar o  
HealthImaging como elemento fundamental do seu conjunto de  
imagens médicas de próxima geração.

“Nossa visão é ajudar os médicos e a equipe a gerenciar cargas de  
trabalho crescentes e otimizar os fluxos de trabalho para acelerar o  
tempo de diagnóstico e tratamento dos pacientes. Os serviços  
específicos da AWS, como o AWS HealthImaging, podem ajudar a  
Philips a inovar com mais rapidez e atender nossos clientes e seus  
pacientes. Nosso HealthSuite Imaging PACS habilitado para nuvem  
pretende usar o AWS HealthImaging para melhorar as experiências  
e a acessibilidade para médicos em todo o mundo.” — Shez

Partovi, Diretor de Inovação e Estratégia e Líder de Negócios de Informática Empresarial, Philips

Mover seus dados de silos locais para a nuvem abre novas oportunidades de inovação. HealthImaging é integrado ao Amazon SageMaker para aprendizado de máquina, proporcionando acesso à computação acelerada por GPU. A NVIDIA está investindo em ferramentas aceleradas por hardware e estruturas de código aberto que funcionam perfeitamente com HealthImaging para avançar no desenvolvimento de algoritmos e na adoção de IA em imagens médicas.

**“MONAI, cofundado e acelerado pela NVIDIA, é uma estrutura de IA de imagens médicas de domínio específico que acelera a tradução de avanços de pesquisa e aplicações de IA em impacto clínico.** Com a integração do MONAI e do AWS HealthImaging, as imagens médicas podem ser visualizadas, processadas e segmentadas quase em tempo real, otimizando os fluxos de trabalho dos médicos, melhorando as experiências dos pacientes e ajudando os hospitais a melhorar a eficiência.” Prerna Dogra, Líder global de produtos de IA para saúde, NVIDIA

Os parceiros também estão facilitando a compreensão dos benefícios do HealthImaging. A Dicomatics é uma empresa de informática médica que oferece uma variedade de soluções, incluindo soluções que auxiliam na migração de dados de classe empresarial de ambientes legados para ambientes modernos baseados em nuvem usando HealthImaging.

**“A Dicomatics é líder na migração contínua e escalável de dados de imagens médicas.** Do local à nuvem, somos excelentes em lidar com migrações complexas e em escala de petabytes. Com o poder do AWS HealthImaging, nossos clientes agora têm um serviço de nuvem especializado dedicado a armazenar seus dados valiosos, alimentando cargas de trabalho clínicas e pesquisas inovadoras.” – Aviram Biton, Parceria Estratégica, Dicomática.

### **Armazenamento econômico para imagens médicas**

HealthImaging fornece armazenamento econômico que pode reduzir o custo total de propriedade para armazenar novos dados e arquivos de imagens de qualquer tamanho. HealthImaging oferece um nível de armazenamento de acesso frequente para dados novos e acessados com frequência e um nível de acesso instantâneo de

arquivamento que é econômico para dados acessados com pouca frequência. Os dados armazenados por mais de 30 dias são movidos automaticamente para a camada de arquivo. O comportamento é semelhante ao da classe de armazenamento Intelligent-Tiering do Amazon Simple Storage Service (Amazon S3), repassando economia de custos aos clientes.

Ambas as camadas de armazenamento do HealthImaging suportam a recuperação de dados em milissegundos. Cada quadro de imagem armazenado no HealthImaging pode ser acessado e renderizado com latência inferior a um segundo, reduzindo a necessidade dos clientes armazenarem dados em volumes caros de armazenamento em bloco.

### **Ingestão e processamento de dados escalonáveis**

Você importa arquivos DICOM P10 para o HealthImaging iniciando trabalhos de importação assíncronos. Você pode aumentar a escala executando vários trabalhos de importação simultaneamente. Arquivos DICOM P10 individuais são importados como quadros de imagem e organizados automaticamente em conjuntos de imagens com metadados consistentes nos níveis do paciente, do estudo e da série. As APIs de cópia e atualização facilitam o gerenciamento de conjuntos de imagens, conforme exigido pelo seu fluxo de trabalho específico.

Os dados de pixel de cada arquivo DICOM P10 são codificados como High-Throughput JPEG 2000 (HTJ2K), um codec de compactação de imagem de última geração que oferece compactação sem perdas eficiente e escalabilidade de resolução. Os clientes com arquivos grandes poderão ver seus volumes de armazenamento reduzidos com o HTJ2K, o que pode ajudar a reduzir custos. HealthImaging valida que todos os dados de pixel foram transcodificados com sucesso, fornecendo somas de verificação para cada quadro de imagem importado. Essas somas de verificação são adicionadas aos metadados do conjunto de imagens, para que você possa verificar de forma independente o processamento de imagem sem perdas ao recuperar um quadro de imagem.

Os metadados nos arquivos DICOM P10, como identificadores de pacientes e detalhes de procedimentos, são automaticamente normalizados nos níveis de paciente, estudo e série. Isso ajuda a eliminar inconsistências e melhorar a qualidade dos dados. Todos

os metadados são preservados, com normalização realizada com base no Registro de Elementos de Dados DICOM. Além disso, os elementos normalizados podem ser acessados com chaves amigáveis ao desenvolvedor, como PatientID, em vez de tags DICOM hexadecimais.

Não há cobrança pela importação de dados para o HealthImaging. A codificação de dados de pixel e a normalização de metadados são realizadas automaticamente. Isso significa que os clientes podem reduzir custos ao migrar para o HealthImaging a partir de uma infraestrutura autogerenciada para ingestão DICOM.

### **APIs otimizadas para aplicações em tempo real**

Os protocolos de transferência de imagens existentes (como DIMSE e DICOMweb) podem fornecer baixo desempenho de latência durante o streaming da nuvem. No entanto, os radiologistas necessitam de experiências de baixa latência para fluxos de trabalho interativos e aplicações de diagnóstico. Portanto, HealthImaging oferece APIs otimizadas para recuperação de dados de pixel e metadados com baixa latência.

**HealthImaging foi desenvolvido especificamente para oferecer desempenho líder do setor em recuperação de dados e carregamento de imagens**, graças à sua codificação eficiente de metadados, compactação sem perdas e suporte para acesso a dados de imagens de resolução progressiva. Aplicativos e algoritmos de IA podem acessar com eficiência os metadados do estudo por meio de APIs, sem a necessidade de carregar dados de imagem. Da mesma forma, os aplicativos podem carregar dados de imagem diretamente por meio de APIs, sem comprometer a qualidade da imagem, graças à compactação de imagem de última geração.

O codec HTJ2K é uma ordem de magnitude mais rápido que o JPEG2000 e pelo menos duas vezes mais rápido que todas as outras sintaxes de transferência DICOM. Com HealthImaging, os aplicativos podem aproveitar o HTJ2K com instruções de dados múltiplos de instrução única (SIMD), para desempenho excepcional de decodificação de imagem. Além disso, os navegadores modernos podem utilizar Web Assembly SIMD (WASM-SIMD) para trazer desempenho líder do setor para visualizadores da web com pegada zero. Assim, o HealthImaging permite que os aplicativos

recuperem e carreguem dados com latências que atendam aos casos de uso interativo mais exigentes.

## Conclusão

Nossos clientes e parceiros estão incansavelmente inovando em nome dos pacientes. A HealthImaging está ajudando-os a fornecer atendimento de alta qualidade a mais pacientes necessitados. O HealthImaging facilita o gerenciamento de dados de imagens médicas em escala de petabytes, com desempenho líder do setor e sem preocupações com infraestrutura.

Você pode começar a usar o HealthImaging lendo a documentação ou aprendendo mais na página da web.

**TAGS:** #healthcare, Amazon HealthLake Imaging, DICOM, hcls, imagens médicas

Tehsin Syed



### AWS Podcast

Subscribe for weekly AWS news and interviews

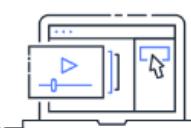
[Learn more »](#)



### AWS Partner Network

Find an APN member to support your cloud business needs

[Learn more »](#)



### AWS Training & Certifications

Free digital courses to help you develop your skills

[Learn more »](#)

## O podcast oficial da AWS

O podcast oficial da AWS é um podcast para desenvolvedores e profissionais de TI que buscam as últimas notícias e tendências em armazenamento, segurança, infraestrutura, sem servidor e muito mais. Junte-se a Simon Elisha, Hawn Nguyen-Loughren e Jillian Forde para atualizações regulares, aprofundamentos, lançamentos e entrevistas. Esteja você treinando modelos de aprendizado de máquina, desenvolvendo projetos de código aberto ou criando soluções em nuvem, o podcast oficial da AWS tem algo para você.

## Imagens médicas

Gerencie dados de imagem e aplique inteligência para extrair insights e melhorar o atendimento ao paciente.

### Inove com insights e otimize o atendimento ao paciente

Com os avanços de qualidade em imagens médicas, as organizações de saúde abrem acesso a capacidade dinâmica, econômica e escalonável para armazenar, analisar e gerenciar dados de imagens médicas. O AWS Marketplace pode radiologistas e sistemas de saúde a gerenciar dados de proteção de imagens, fornecendo soluções inovadoras de gerenciamento de imagens médicas.

### Modernização com Cloud PACS por meio do AWS Marketplace

Saiba como o AWS Marketplace pode ajudá-lo a permitir a adoção bem-sucedida de uma solução PACS em nuvem.

### Assistir ao webinar

### Soluções de imagens médicas no AWS Marketplace

As soluções de terceiros a seguir no AWS Marketplace foram projetadas especificamente para ajudar as organizações de saúde a aprimorar o atendimento ao paciente, reduzir custos e melhorar os resultados em todo o atendimento contínuo.

### Apresentando o AWS HealthImaging — desenvolvido especificamente para imagens médicas em grande escala

por Tehsin Syed e Andy Schuetz | em 25 de julho de 2023 | no Amazon Simple Storage Service (S3), AWS DataSync, AWS Direct Connect, AWS HealthImaging, Saúde, Indústrias | Link permanente | Comentários | Compartilhar

Temos o prazer de anunciar a disponibilidade geral do AWS HealthImaging, um serviço desenvolvido especificamente que ajuda os construtores a desenvolver aplicativos nativos da nuvem que armazenam, analisam e compartilham dados de imagens médicas em escala de petabytes. HealthImaging ingere dados no formato DICOM P10. Ele fornece APIs para recuperação de baixa latência e armazenamento específico.

Nossos clientes do setor de saúde nos dizem que desejam que suas equipes de atendimento tenham os melhores aplicativos de imagens médicas e que desejam reduzir a complexidade do gerenciamento da infraestrutura. Nossos clientes focados em pesquisa desejam analisar dados de imagens em escala e acelerar a colaboração e a descoberta em suas organizações. Ambos os grupos de clientes expressam o desejo de que todos os aplicativos de imagens médicas de suas organizações funcionem a partir do mesmo armazenamento de dados. A nuvem pode ajudar a atender a essas necessidades dos clientes. Com o HealthImaging, os construtores, como os parceiros da AWS que fornecem aplicativos de imagens médicas e soluções de pesquisa, podem se concentrar mais em enfrentar os desafios desses clientes, em vez de se preocuparem com a infraestrutura.

### **Expansão da imagem médica na prestação de cuidados e pesquisa**

Por mais de 100 anos, os profissionais de saúde têm usado imagens médicas, como raios X, ressonância magnética e ultrassom, para observar o interior dos pacientes de forma não invasiva. A ganhadora do Prêmio Nobel Marie Curie foi uma das pioneiras em imagens médicas. Ela desenvolveu veículos com equipamentos de raios X, chamados “petite Curies”, para ajudar os cirurgiões do campo de batalha a prestarem melhores cuidados durante a Primeira Guerra Mundial. Hoje, as imagens médicas são usadas para diagnosticar e monitorar uma ampla gama de condições de saúde, abrangendo oncologia, trauma, acidente vascular cerebral e muito mais. Globalmente, mais de 3,6 bilhões de procedimentos de imagens médicas são realizados a cada ano, gerando coletivamente exabytes de dados de imagens médicas.



Os parceiros da AWS estão inovando em nome dos clientes

Os parceiros da AWS já estão usando o HealthImaging para reimaginar as soluções de imagens médicas usadas por radiologistas, equipes de atendimento e pesquisadores.

Wake Forest Baptist Health está tornando o conteúdo clínico mais acessível aos estudantes de radiologia, com soluções da Apollo Enterprise Imaging e HealthImaging.

“Precisamos da capacidade de dimensionar, compartilhar e visualizar imagens médicas para pesquisa e educação em toda a nossa empresa e com colaboradores em todo o mundo. Trabalhar em colaboração com a Apollo EI, usando o AWS HealthImaging e suas tecnologias de ponta de repositório de imagens empresariais, torna isso possível.” — Josh Tan, gerente de sistemas da Wake Forest Baptist Health

A Philips, líder global em imagens médicas, pretende usar o HealthImaging como elemento fundamental do seu conjunto de imagens médicas de próxima geração.

“Nossa visão é ajudar os médicos e a equipe a gerenciar cargas de trabalho crescentes e otimizar os fluxos de trabalho para acelerar o tempo de diagnóstico e tratamento dos pacientes. Os serviços específicos da AWS, como o AWS HealthImaging, podem ajudar a Philips a inovar com mais rapidez e atender nossos clientes e seus pacientes. Nossa HealthSuite Imaging PACS habilitado para nuvem pretende usar o AWS HealthImaging para melhorar as experiências e a acessibilidade para médicos em todo o mundo.” — Shez

Partovi, Diretor de Inovação e Estratégia e Líder de Negócios de Informática Empresarial, Philips

Mover seus dados de silos locais para a nuvem abre novas oportunidades de inovação. HealthImaging é integrado ao Amazon SageMaker para aprendizado de máquina, proporcionando acesso à computação acelerada por GPU. A NVIDIA está investindo em ferramentas aceleradas por hardware e estruturas de código aberto que funcionam perfeitamente com HealthImaging para avançar no desenvolvimento de algoritmos e na adoção de IA em imagens médicas.

“MONAI, cofundado e acelerado pela NVIDIA, é uma estrutura de IA de imagens médicas de domínio específico que acelera a tradução de avanços de pesquisa e aplicações de IA em impacto clínico. Com a integração do MONAI e do AWS HealthImaging, as imagens médicas podem ser visualizadas, processadas e segmentadas quase em tempo real, otimizando os fluxos de trabalho dos médicos, melhorando as experiências dos pacientes e ajudando os hospitais a melhorar a eficiência.” Prerna Dogra, Líder global de produtos de IA para saúde, NVIDIA

Os parceiros também estão facilitando a compreensão dos benefícios do HealthImaging. A Dicomatics é uma empresa de informática médica que oferece uma variedade de soluções, incluindo soluções que auxiliam na migração de dados de classe empresarial de ambientes legados para ambientes modernos baseados em nuvem usando HealthImaging.

“A Dicomatics é líder na migração contínua e escalável de dados de imagens médicas. Do local à nuvem, somos excelentes em lidar com migrações complexas e em escala de petabytes. Com o poder do AWS HealthImaging, nossos clientes agora têm um serviço de nuvem especializado dedicado a armazenar seus dados valiosos, alimentando cargas de trabalho clínicas e pesquisas inovadoras.” – Aviram Biton, Parceria Estratégica, Dicomática.

## Armazenamento econômico para imagens médicas

**HealthImaging fornece armazenamento econômico que pode reduzir o custo total de propriedade para armazenar novos dados e arquivos de imagens de qualquer tamanho.**

HealthImaging oferece um nível de armazenamento de acesso

frequente para dados novos e acessados com frequência e um nível de acesso instantâneo de arquivamento que é econômico para dados acessados com pouca frequência. Os dados armazenados por mais de 30 dias são movidos automaticamente para a camada de arquivo. O comportamento é semelhante ao da classe de armazenamento Intelligent-Tiering do Amazon Simple Storage Service (Amazon S3), repassando economia de custos aos clientes.

Ambas as camadas de armazenamento do HealthImaging suportam a recuperação de dados em milissegundos. Cada quadro de imagem armazenado no HealthImaging pode ser acessado e renderizado com latência inferior a um segundo, reduzindo a necessidade dos clientes armazenarem dados em volumes caros de armazenamento em bloco.

## Ingestão e processamento de dados escalonáveis

Você importa arquivos DICOM P10 para o HealthImaging iniciando trabalhos de importação assíncronos. Você pode aumentar a escala executando vários trabalhos de importação simultaneamente. Arquivos DICOM P10 individuais são importados como quadros de imagem e organizados automaticamente em conjuntos de imagens com metadados consistentes nos níveis do paciente, do estudo e da série. As APIs de cópia e atualização facilitam o gerenciamento de conjuntos de imagens, conforme exigido pelo seu fluxo de trabalho específico.

Os dados de pixel de cada arquivo DICOM P10 são codificados como High-Throughput JPEG 2000 (HTJ2K), um codec de compactação de imagem de última geração que oferece compactação sem perdas eficiente e escalabilidade de resolução. Os clientes com arquivos grandes poderão ver seus volumes de armazenamento reduzidos com o HTJ2K, o que pode ajudar a reduzir custos. HealthImaging valida que todos os dados de pixel foram transcodificados com sucesso, fornecendo somas de verificação para cada quadro de imagem importado. Essas somas de verificação são adicionadas aos metadados do conjunto de imagens, para que você possa verificar de forma independente o processamento de imagem sem perdas ao recuperar um quadro de imagem.

Os metadados nos arquivos DICOM P10, como identificadores do paciente e detalhes do procedimento, são automaticamente normalizados no paciente, estudo

## **Os mercados de nuvem aceleram a transformação digital na área da saúde**

**Descubra tendências emergentes de nuvem para acelerar a transformação digital e veja como as organizações de saúde estão aproveitando o AWS Marketplace para simplificar a implantação de software.**

### **Benefícios**

#### **Seleção, velocidade e agilidade**

**Adquira e implante rapidamente produtos de vendedores de assistência médica que atendam à sua necessidade de liberar o valor dos dados e inovar a experiência de atendimento ao paciente.**

#### **Preços e termos flexíveis**

**Acesse opções de preços que oferecem flexibilidade para testar software, pagar conforme o uso, negociar termos personalizados e economizar dinheiro com compromissos de longo prazo.**

#### **Controle e governança**

**Centralize a governança, inove rapidamente e lance software de saúde ou produtos de dados de terceiros que se alinhem com suas políticas e requisitos de conformidade**

#### **Interoperabilidade avançada na área da saúde**

**Obtenha insights de uma pesquisa recente sobre interoperabilidade e saiba como o AWS Marketplace pode ajudar a orientar e aprimorar suas estratégias de interoperabilidade.**

**Acelere a transformação digital na área da saúde**

**Saiba como a Accenture e o AWS Marketplace podem ajudar você a construir um ecossistema mais poderoso para transformar e inovar o atendimento.**

**Os líderes do setor de saúde estão aproveitando as novas tecnologias, usando soluções de software em nuvem e aproveitando insights de dados em escala para acelerar a inovação e a transformação digital em toda a empresa. Este white paper destaca como as soluções da Accenture e de terceiros disponíveis no AWS Marketplace estão permitindo que as organizações de saúde personalizem tratamentos e melhorem o desempenho. Leia agora para saber como essas soluções podem ajudá-lo a construir um ecossistema mais poderoso para transformar e inovar os cuidados.**

**Leia este whitepaper para:**

- **Descubra tendências emergentes de nuvem para acelerar a transformação digital.**
- **Adote as melhores práticas para inovar e adquirir soluções de software em nuvem.**

- Saiba como as organizações de saúde estão aproveitando o AWS Marketplace para simplificar a implantação de software.

**Clique aqui para saber mais sobre as soluções de saúde disponíveis no AWS Marketplace. Healthcare solutions and software in AWS Marketplace**

Find purpose-built solutions you need to enhance patient care, lower costs, and improve outcomes throughout the continuum of care

### **Selection, speed, and agility**

Quickly procure and deploy products from healthcare partners that address your need to unlock the value of data and innovate the patient care experience.

### **Flexible pricing and terms**

Access pricing options that give you the flexibility to test software, pay as you go, negotiate custom terms, and save money with long-term commitments.

### **Control and governance**

Centralize governance, innovate quickly, and launch healthcare software or third-party data products that align with your policies and compliance requirements.

## **Promova a inovação e melhore os resultados dos pacientes com soluções de saúde no AWS Marketplace**

Os líderes do setor de saúde estão acelerando a inovação e a transformação digital, aproveitando soluções, software e ferramentas de saúde na nuvem para aproveitar insights de dados em escala. O AWS Marketplace oferece um catálogo selecionado de soluções de terceiros que podem ajudar você a modernizar o atendimento, melhorar os resultados dos pacientes, cumprir regulamentações e aproveitar o potencial dos dados de saúde. Seja você um provedor, um pagador ou uma organização de tecnologia de saúde, o AWS Marketplace pode ajudá-lo a descobrir, adquirir,

implantar e gerenciar facilmente soluções de tecnologia de nuvem e gerenciamento de dados.

## [AWS re:Invent spotlight | Simplify healthcare compliance](#)

AWS Marketplace takes the stage at this year's AWS re:Invent to share how solutions in AWS Marketplace can simplify healthcare compliance.

**Large scale AI in digital pathology without the heavy lifting**  
by Moritz Widmaier, Martin Schulze, Florian Leiss, Ruben Cardenes, and Razvan Ionasec | on 02 MAR 2023 | in [Amazon Machine Learning, Artificial Intelligence, AWS For Startups, Customer Solutions, Healthcare, Public Sector, Startup](#) | [Permalink](#) | [Comments](#) | [Share](#)

*Pictured: Tissue sample stained with H&E and immunofluorescence (IF) markers side by side.*

*This is a guest post by Moritz Widmaier, product manager; Martin Shulze, principal consultant for technology and IT; and Florian Leiss, vice president (VP) of product strategy and corporate development, at Ultivue.*

Pathology is currently undergoing a transformation. While microscopes still dominate many workflows, digital pathology combined with artificial intelligence (AI) is disrupting the space. Together they unlock the pathway to precision medicine and will be among our strongest weapons to fight cancer. Pathologists have been looking at morphological patterns in patients' tissue sections highlighted by Hematoxylin and Eosin (H&E) staining for more than a century. They accumulated a comprehensive body of knowledge on how combined insights from tissue and cell morphologies characterize disease and guide treatment selection. AI tools can complement expert assessment with quantitative measurements to enable data-driven medicine. AI companies have formed on the idea that AI can complement the expert assessment of H&E slides by a pathologist.

[Ultivue](#) is one such healthcare technology (HealthTech) company that provides high-quality multiplex immunofluorescence assays and

large-scale, AI-based computational pathology—built on Amazon Web Services (AWS).

## Tissue analysis in color

With the advent of immune therapy, a more granular characterization of the immune system (and tumor cells) has become necessary to support clinical pathology and diagnostics.

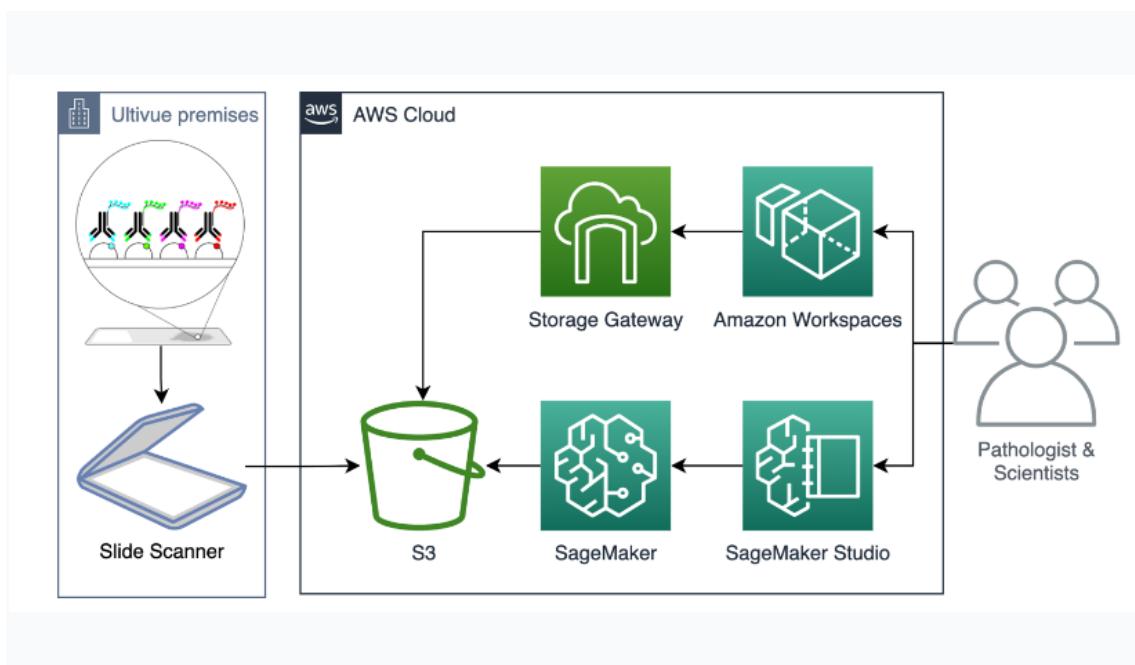
At a high level, our immune system comprises multiple different cell types (T cell, B cell, etc.), which are difficult to distinguish in H&E slides. To complicate things, most of these cell types can be subdivided into a vast number of “specializations” and states of activities that cannot be distinguished from H&E slides anymore. Neither pathologists nor AI can reveal the required information from H&E sections since it was not captured when the tissue section was stained and digitized. Trying to understand the tumor-immuno microenvironment through the eyes of ‘Digital Pathology’ (i.e. only looking at H&E stained sections) can be compared to using black-and-white photography to spot yellow tulips in a red tulip field.

Immunofluorescence is the color photography equivalent of pathology. It allows us to see many more cell phenotypes by adding highly specific staining channels, and with the help of AI, their spatial relationships, or spatial biology.

Ultivue combines expertise in the development of high-quality multiplex immunofluorescence assays and AI-based computational pathology. We aim to deeply characterize immune cells and tumor cell and their spatial relationships in the context of intact tissue, using AI to analyze tissue images at scale. This presents multiple challenges. Our multiplex immunofluorescence images can have five billion pixels and more than five, sometimes 13 channels. These images can get as large as 100 GB. Images at the scale of 10 to 100 GB present a different order of magnitude to what many systems are built for – including systems built to analyze H&E images in pathology. Experts developing these tissue assays and understanding the scientific intricacies in the rich image data mostly aren’t AI engineers and cloud architects. They want algorithms to support the interpretation of the images to generate results quickly, without having to write or read code.

## Handling over 10 GB images on AWS

Amazon Simple Storage Service ([Amazon S3](#)) provides a cost-effective and scalable solution for storing this data, and in combination with [AWS Storage Gateway](#), traditional block-storage-like access is achievable. AWS Storage Gateway is an important part of our solution, as many of the common tools that pathologists and scientists rely on would cease to function without it. However, these commonly used tools that run on a Windows Desktop do not scale very well. That's where [Amazon SageMaker](#) comes in.



*Figure 1. The Ultivue architecture using Amazon S3, AWS Storage Gateway, Amazon SageMaker, and Amazon SageMaker Studio as key components.*

For this solution, we use [Amazon S3 with Intelligent-Tiering](#) to store data in a cost-effective manner with low-latency access. Storage Gateway provides file shares via the SMB network file system that Windows clients can use. [Amazon WorkSpaces](#) provides a pre-configured desktop working environments to our users, including the Storage Gateway-backed network drives.

[Amazon SageMaker Studio](#) enables cloud working environments for AI engineers, as well as pathologists. We use Amazon SageMaker's processing, training, and inference APIs to analyze images at any scale.

## **Amazon SageMaker Studio as a user interface for non-technical users**

When handling data at the scale that Ultivue does, the need for utilizing the scalability of cloud services is omnipresent. However, the bio-technology space requires medical and biological experts that cannot be experts in software and IT at the same time. Our user interfaces must simplify the use of highly scalable compute services, such as Amazon SageMaker, and at the same time, offer flexibility to a wide range of users, like AI engineers.

Utilizing custom images and lifecycle configurations allows Ultivue to provide an internal app-store-like experience on top of the highly flexible Amazon SageMaker Studio interface.

In the past, image analysis experts and AI engineers worked with software engineers to integrate algorithms into custom processing environments and connect them to different data sources. Now, processing at scale and data pipelines are reduced to API calls, and image analysis experts can make their algorithms available to pathologists without any intermediary needed.

### **From pixel to object**

Without image analysis, information-rich multi-channel images are just images. Humans, even trained experts, are limited by—in the best case—the presence of only three-color receptors in our retina. Consequently, it becomes increasingly difficult to visually process the information coming from the 5-13 channels that are typically used with Ultivue technology, let alone considering the interactions of potentially dozens, if not a hundred, different cell types across millions of cells present in a tissue section.

AI-based image analysis gives us the opportunity to classify millions of cells and interrogate their frequency and spatial relationships in a data-driven way. This can help find out which specific immune cells need to talk to other immune cells or interact with a subset of tumor cells to predict therapy outcome, and more.

Visit [Ultivue](#) to learn more about this solution.

*Learn more about how healthcare and life science organizations use AWS at [AWS for Health](#). Do you want to learn more about how to use AWS for digital pathology and other healthcare solutions? [Contact the AWS Public Sector Team here](#).*

*Pictured: Classified cells overlayed on IF image as image analysis detected them.*

## Read more about AWS for healthcare:

- [How Digithurst and Telepaxx built a secure and scalable radiology solution chain using AWS](#)
- [AMILI helps advance precision medicine by building microbiome library on AWS](#)
- [Helping prevent sudden cardiac arrest in young athletes with AI](#)
- [How KHUH built a long-term storage solution for medical image data with AWS](#)
- [Solving medical mysteries in the AWS Cloud: Medical data-sharing innovation through the Undiagnosed Diseases Network](#)

[Subscribe to the AWS Public Sector Blog newsletter](#) to get the latest in AWS tools, solutions, and innovations from the public sector delivered to your inbox, or [contact us](#).

[Please take a few minutes to share insights regarding your experience with the AWS Public Sector Blog in this survey](#), and we'll use feedback from the survey to create more content aligned with the preferences of our readers.

TAGS: [Amazon Sagemaker](#), [healthcare](#), [life sciences](#), [Machine Learning](#), [machine learning on AWS](#), [medical imaging](#), [public sector](#), [public sector startups](#), [startup](#)

## Annotate DICOM images and build an ML model using the MONAI framework on Amazon SageMaker

**DICOM (Digital Imaging and Communications in Medicine)** is an image format that contains visualizations of X-Rays and MRIs as well as any associated metadata. DICOM is the standard for medical professionals and healthcare researchers for visualizing and interpreting X-Rays and MRIs. The purpose of this post is to solve two problems:

- Visualize and label DICOM images using a custom data labeling workflow on [Amazon SageMaker Ground Truth](#), a fully managed data labeling service supporting built-in or custom data labeling workflows
- Develop a DenseNet image classification model using the [MONAI](#) framework on [Amazon SageMaker](#), a comprehensive and fully managed data science platform with purpose-built tools to prepare, build, train, and deploy machine learning (ML) models on the cloud

For this post, we use a chest X-Ray DICOM images dataset from the [MIMIC Chest X-Ray \(MIMIC-CXR\) Database](#), a publicly available database of chest X-Ray images in DICOM format and the associated radiology reports as free text files. To access the files, you must be a [registered user](#) and [sign the data use agreement](#).

We label the images through the Ground Truth private workforce. AWS can also provide professional managed workforces with experience labeling medical images.

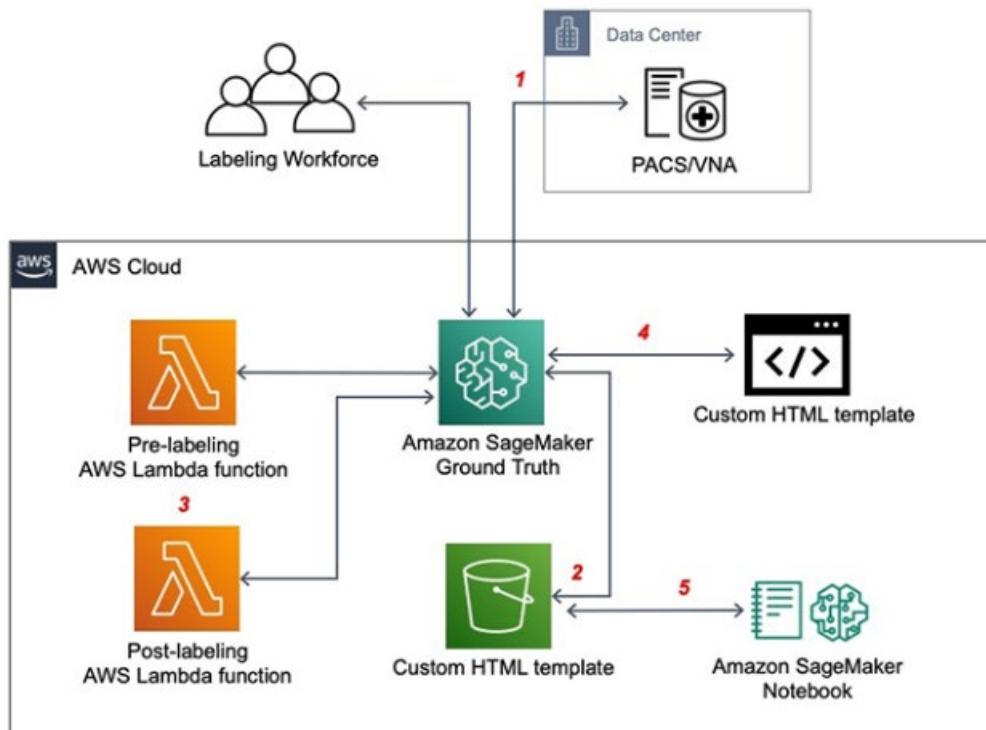
## Solution overview

The following diagram shows the high-level workflow with the following key components:

1. The DICOM images are stored in a third-party [picture archiving and communication system](#) (PACS) or [Vendor Neutral Archive](#) (VNA), and retrieved through [DICOMweb™](#).
2. An [input manifest.json file](#) is uploaded to [Amazon Simple Storage Service](#) (Amazon S3). The file contains the DICOM instance ID as the data source and potential labels used by annotators when they perform the labeling jobs.
3. Two [AWS Lambda](#) functions are essential for creating labeling jobs on Ground Truth:
  - A pre-labeling function reads the DICOM image ID from the manifest.json file and creates the task input object that is fed into the [Liquid HTML template for automation](#).
  - A post-labeling processing function [consolidates the annotations from different labeling jobs](#).
4. A [HTML template with Crowd elements](#) for submitting the labeling jobs and processing the output object. Subsequently,

the output of labeling jobs is saved in an output label S3 bucket.

5. A [SageMaker notebook](#) can retrieve the outputs of labeling jobs and use them to train a supervised ML model.



## *Amazon Rekognition*

**Automatize e reduza o custo de seu  
reconhecimento de imagem e análise de vídeo  
com machine learning**

Adicione rapidamente APIs de visão computacional pré-treinadas ou personalizáveis às suas aplicações sem precisar construir modelos de machine learning (ML) e infraestrutura do zero

Analise milhões de imagens, transmissões e vídeos armazenados em minutos, complementando as tarefas de revisão visual humana com a inteligência artificial (IA)

Aumente ou reduza a escala verticalmente com base nas necessidades da sua empresa com recursos de IA totalmente gerenciados e pague apenas pelas imagens e vídeos que analisar.

#### O que o Amazon Rekognition pode fazer?

Saiba como o Amazon Rekognition pode capacitar suas equipes comerciais e de desenvolvimento a resolver as necessidades de visão computacional mais exigentes, sem precisar de conhecimentos em ML e com custo mais baixo

#### Vivacidade dos rostos

Em questão de segundos, detecte usuários reais e impeça a ação de malfeiteiros que utilizam falsificações durante a verificação facial.

#### Comparação de rostos e pesquisas

Determine a semelhança de um rosto com outra imagem ou do seu repositório de imagens privado.

#### Detecção e análise de faces

Detecte rostos que aparecem em imagens e vídeos e reconheça atributos como olhos abertos, óculos e pelos faciais para cada um.

#### Moderação de conteúdo

Detecte conteúdo potencialmente inseguro, inapropriado ou indesejado em imagens e vídeos.

#### Rótulos personalizados

Detecte objetos personalizados, como logotipos de marca, usando machine learning automatizado (AutoML) para treinar seus modelos com apenas 10 imagens.

#### Detecção de texto

Extraia texto distorcido e inclinado de imagens e vídeos de placas de rua, postagens de mídia social e embalagens de produtos.

#### Rótulos

Detecte objetos, cenas, atividades, marcos, cores dominantes e a qualidade da imagem.

## **Detecção de segmento de vídeo**

Detecte os principais segmentos em vídeos, como quadros pretos, créditos iniciais ou finais, listas, barras de cores e fotos.

## **Reconhecimento de celebridades**

Identifique pessoas conhecidas para catalogar fotos e filmagens para mídia, marketing e publicidade.

## **Detectar conteúdo impróprio**

Identifique com rapidez e precisão conteúdo inseguro ou inadequado em ativos de imagem e vídeo com base em padrões e práticas gerais ou específicos da empresa.

## **Simplifique a análise de mídia**

Detecte automaticamente os principais segmentos de vídeo para reduzir o tempo, o esforço e os custos de inserção de anúncios em vídeo, operações de conteúdo e produção de conteúdo.

## **Envie alertas inteligentes a residências conectadas**

Envie alertas acionáveis e oportunos quando um objeto desejado for detectado em uma transmissão de vídeo ao vivo. Crie experiências de automação residencial, como acender automaticamente uma lâmpada quando uma pessoa for detectada.

# **Deep learning frameworks for diabetic retinopathy detection with smartphone-based retinal imaging systems**

## **Abstract**

Diabetic Retinopathy (DR) may result in various degrees of vision loss and even blindness if not diagnosed in a timely manner. Therefore, having an annual eye exam helps early

detection to prevent vision loss in earlier stages, especially for diabetic patients. Recent technological advances made smartphone-based retinal imaging systems available on the market to perform small-sized, low-powered, and affordable DR screening in diverse environments. However, the accuracy of DR detection depends on the field of view and image quality. Since smartphone-based retinal imaging systems have much more compact designs than a traditional fundus camera, captured images are likely to be the low quality with a smaller field of view. Our motivation in this paper is to develop an automatic DR detection model for smartphone-based retinal images using the deep learning approach with the ResNet50 network. This study first utilized the well-known AlexNet, GoogLeNet, and ResNet50 architectures, using the transfer learning approach. Second, these frameworks were retrained with retina images from several datasets including EyePACS, Messidor, IDRiD, and Messidor-2 to investigate the effect of using images from the single, cross, and multiple datasets. Third, the proposed ResNet50 model is applied to smartphone-based synthetic images to explore the DR detection accuracy of smartphone-based retinal imaging systems. Based on the vision-threatening diabetic retinopathy detection results, the proposed approach achieved a high classification accuracy of 98.6%, with a 98.2% sensitivity and a 99.1% specificity while its AUC was 0.9978 on the independent test dataset. As the main contributions, DR detection accuracy was improved using the transfer learning approach for the ResNet50 network with publicly available datasets and the effect of the field of view in smartphone-based retinal imaging was studied. Although a smaller number of images were used in the training set compared with the existing studies, considerably acceptable high accuracies for validation and testing data were obtained.

## Introduction

Based on data from the World Health Organization, 422 million people have diabetes in 2014 around the world, and the number is predicted to be 552 million by 2030 [1]. The US Department of Health and Human Services National Diabetes Statistics Report [2] demonstrates that an estimation of 30.5 million in the US population (10.5 percent) has diabetes in 2020, with 7.3

million people undiagnosed, among all age groups. Individuals with diabetes are at high risk of diabetic eye diseases such as Diabetic Retinopathy (DR), Diabetic Macular Edema (DME), and Glaucoma. DR, the most suffered disease among all others, is caused by the damaging of blood vessels in the retina. The signs of DR can be listed as including but not limited to the existence of microaneurysms, vitreous hemorrhage, hard exudates, and retinal detachment. Fig. 1 shows retina images with different DR levels such as (a) normal, (b) mild, (c) moderate, (d) severe, and (e) proliferative.

It is projected that 14 million people will have DR in the US by 2050 [3]. If the detection of DR is not conducted at earlier stages, it may result in various degrees of vision impairment and even blindness. Therefore, a diabetic person must have an annual eye screening. Since developing countries suffer from high DR percentages, the lack of equipment is the main barrier to early diagnosis of DR. Besides, patients in rural areas may not have access to the state-of-the-art diagnosis devices, such as fundus cameras. Even if they have enough equipment, image analysis can take 1–2 days by an ophthalmologist. Hence, there is a growing demand for portable and inexpensive smartphone-based devices and automation of detecting such eye diseases.

Recent advances in computing and imaging technologies have enabled scientists to design small-sized, low-power, and affordable biomedical imaging devices using smartphones. These devices are capable of imaging, onboard processing, and wireless communication. Since they make existing systems small and portable, smartphone-based systems are widely used in several applications, ranging from health care to entertainment. Due to their large size, heavy weight, and high price, traditional fundus cameras are a good candidate to be transformed into a portable smartphone-based device to perform fast DR screening. The development of smartphone-based portable retinal imaging systems is an emerging research and technology area that attracts several universities and companies.

Holding a 20D lens in front of a smartphone camera is the simplest smartphone-based design to capture retina images [4].

Welch Allyn developed the iExaminer [5] system by attaching a smartphone to a PanOptic ophthalmoscope as shown in Fig. 2(a). These systems are built by attaching a smartphone to an existing medical device. There already exist several standalone designs for smartphone-based retinal imaging in the market including D-Eye, Peek Retina, and iNview. D-Eye [6] is the smallest retinal imaging system to capture retina images as an attachment to a smartphone as shown in Fig. 2(b). It illuminates the retina using the reflection of the smartphone's flashlight next to the camera without requiring additional external light and power sources. Its optics design allows it to capture images at 20 degrees in angle for dilated eyes. To simplify the design and to have evenly distributed illumination, the Peek Retina system [7] uses a circular placed multiple-LED light source to illuminate the retina as shown in Fig. 2(c). The iNview [8] was developed by Volk Optical as a new wide-angle smartphone-based retinal imaging system as shown in Fig. 2(d). For illumination, since iNview uses the reflection of the smartphone's flashlight, it does not require external light. Also, iNview can visualize the entire posterior pole in a single image by capturing 50 degrees of retinal view. Table 1 summarizes the hardware specifications of the publicly available smartphone-based imaging systems. Also, iExaminer, D-Eye, and iNview have Food and Drug Administration (FDA) approval. However, Peek Retina is currently waiting for its approval. Although these smartphone-based systems can capture retina images, none of them offers a solution to evaluate disease by analyzing the images with machine learning and image processing methods.

Since deep learning techniques, especially Convolutional Neural Networks (CNNs), are an emerging research area, different research communities have already applied CNNs for several applications, including DR detection [9]. Deep learning is widely used for image classification tasks using neural networks that calculate hundreds of mathematical equations with millions of parameters. Recent works in the literature related to DR detection have mainly focused on designing new algorithms for traditional fundus images that are primarily affected by occlusion, refraction, variations in illumination, and blur. Kaggle competition is one of the important breakthroughs for DR detection where the EyePACS retina image dataset was

presented with 35,126 training and 53,576 testing images. It attracted researchers and data scientists all over the world where several deep learning solutions were presented to detect DR.

Abramoff et al. [10,11] developed the Iowa Detection Program using their dataset and Messidor-2 dataset for training and testing. They have presented a variety of DR definitions such as referable Diabetic Retinopathy (rDR), vision-threatening Diabetic Retinopathy (vtDR), and referable Diabetic Macular Edema (rDME). They also reported high detection performance for rDR and vtDR. Gulshan et al. also developed CNN based deep learning frameworks for DR detection [12]. They trained the Inception-v3 architecture [13] with 128,175 images from EyePACS and Messidor-2 datasets and achieved high sensitivity and specificity. Gargya et al. [14] used a customized CNN architecture to classify images into two categories: healthy vs. others with any DR stage. They trained their network with 75,137 fundus images from their dataset, tested with Messidor-2 and E-Ophtha datasets, and achieved high accuracy.

Instead of training the CNNs from scratch, the transfer learning approach was used for pretrained deep learning frameworks [15], [16], [17], [18], [19]. Lam et. al. [15] proposed using pretrained CNN-based deep learning frameworks to detect DR using various classification models including but not limited to 2-ary, 3-ary, and 4-ary. They investigated the transfer learning approach for AlexNet [16] and GoogLeNet [17] using images in EyePACS and Messidor-1 datasets. They suggested using image pre-processing to increase validation accuracy, especially for the detection of mild DR. They augmented the retina images to increase the number of images in the training set and to prevent overfitting. Their results showed high sensitivity and specificity. Pires et al. [18] also proposed using transfer learning techniques for rDR detection. For training, they applied data augmentation, multi-resolution, and feature extraction to images in EyePACS dataset. They tested the network with Messidor-2 dataset and showed high rDR detection accuracy. Besides, Li et al [19] presented the binary and multi-class DR detection methods using the transfer learning for the Inception-v3 network. They trained the network with 19,233 images from their dataset and

tested with Messidor-2 dataset. Their high accuracy results were comparable with the accuracy of three independent experts.

EyeArt is a cloud-based retina image assessment tool to detect DR using deep learning. It is capable of image description, image normalization, image rejection, region of interest detection, and descriptor computation. Solanki et al. [20] tested EyeArt with Messidor-2 dataset and achieved high accuracy. Rajalakshmi et al. [21] presented an early work to detect DR using EyeArt at retina images captured by Fundus On Phone (FOP) device. FOP proves the concept of smartphone-based designs and shows the technological and economic feasibility of the portable retinal imaging systems. Although all these related works achieved superior performance with high-quality fundus images, there were some limitations for smartphone-based retinal images. Due to their fewer controllable parameters and inexpensive lenses, smartphone-based systems have a smaller field of view and lower image quality compared to the fundus camera and FOP. Also, some existing methods [10], [11], [12], [13], [14] trained the CNNs from scratch that required very large labeled retina images and an extremely long time for the training process. Therefore, the existing approaches could not be applied directly to the retina images captured with smartphone-based systems because the field of view and image quality play important roles at the accuracy of the deep learning frameworks.

To address the above challenges and maximize the clinical utility of smartphone-based systems, this study explored the transfer learning frameworks for automatic DR detection. Our motivation in this paper is to develop an automatic DR detection model for smartphone-based retinal images using the deep learning approach with the pretrained networks. The main contributions of this article are two-fold: (i) to improve DR detection accuracy using the transfer learning approach for the pretrained networks with publicly available datasets and (ii) to study the effect of the Field of Views (FoVs) of smartphone-based retinal imaging devices. This study, with its high accuracy, high sensitivity, and high specificity, could help to design affordable and portable retinal imaging systems attached to smartphones that can be used by a variety of professionals

ranging from ophthalmologists to nurses. It allows distributing quality eye care to virtually any location with the lack of access to eye care. Since recent patients are more involved in the monitoring and care of their diseases, there is an increasing trend in at-a-distance or telemedicine efforts to provide health care services for individuals living in far rural areas. For example, the teleophthalmology program based on the Joslin Vision Network was designed for DR screening and showed that it is a less costly and more effective strategy to examine the DR than conventional clinical-based screening [22]. This is clear evidence that smartphone-based retinal imaging systems will improve the technical capability and clinical practice for DR screening, increase the rate of access to DR imaging, and will help to decrease blindness due to DR even for individuals at distant locations from the health care facilities.

## **Methods**

This section presented the general structure of the utilized deep learning architectures using transfer learning approach. Deep learning is capable of learning those structures by extracting the required information from the network using training images. It does not require extracting vein structures and identifying lesions such as exudates, microaneurysms, and hemorrhages at the retina for diabetic retinopathy detection. Therefore, training is an essential part of any deep learning system

## **Experimental setup and datasets**

This study was carried out using several publicly available retina image datasets, including EyePACS [25], Messidor [26], Messidor-2 [27], IDRiD [28], and University of Auckland Diabetic Retinopathy (UoA-DR) [29,30]. EyePACS is the largest publicly available dataset that was offered during Kaggle competition with 35,126 retina images that includes five different DR severity labels. Messidor DR dataset contains 1187 images with four labels and DME grades. Messidor-2 dataset is an extension of

## **Results and discussion**

This section first presented the results of our pretrained networks for the original fundus camera images to investigate their strengths and weaknesses by comparing them with the published works to support the novelty of our proposed approach. Second, we investigated the effect of using retina images from the single, cross, and merged datasets in training and validation. Third, these results were also compared with the smartphone-based synthetic retina images to explore the effect of FoVs for

## Conclusion

This paper presented the utility of CNN-based AlexNet, GoogLeNet, and ResNet50 frameworks to improve the performance of DR detection in smartphone-based and traditional fundus camera retina images. This study allowed us to compare the deep learning frameworks and to study the effect of FoVs in smartphone-based retinal imaging systems on their DR detection accuracy. Based on our results, the proposed ResNet50 approach showed the highest accuracy, sensitivity, and specificity for validation and

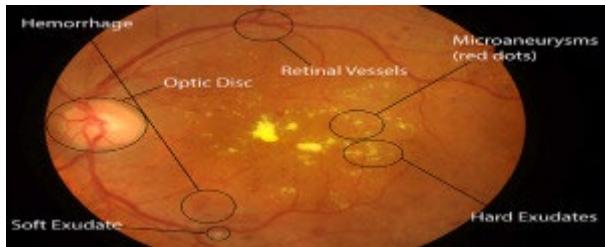
# A survey on medical image analysis in diabetic retinopathy

## Abstract

Diabetic Retinopathy (DR) represents a highly-prevalent complication of diabetes in which individuals suffer from damage to the blood vessels in the retina. The disease manifests itself through lesion presence, starting with microaneurysms, at the nonproliferative stage before being characterized by neovascularization in the proliferative stage. Retinal specialists strive to detect DR early so that the disease can be treated before substantial, irreversible vision loss occurs. The level of DR severity indicates the extent of treatment necessary - vision loss may be preventable by effective diabetes management in mild (early) stages, rather than subjecting the patient to invasive laser surgery. Using artificial intelligence (AI), highly accurate and efficient systems can be developed to help assist medical professionals in screening and diagnosing DR earlier and without the full resources that are available in specialty clinics. In particular, deep learning facilitates diagnosis earlier and with higher sensitivity and specificity. Such systems make decisions based on minimally handcrafted features and pave the way for personalized therapies. Thus, this survey provides a comprehensive description of the current

technology used in each step of DR diagnosis. First, it begins with an introduction to the disease and the current technologies and resources available in this space. It proceeds to discuss the frameworks that different teams have used to detect and classify DR. Ultimately, we conclude that deep learning systems offer revolutionary potential to DR identification and prevention of vision loss.

## Graphical abstract



1. [Download : Download high-res image \(202KB\)](#)
2. [Download : Download full-size image](#)

## Introduction

Diabetic Retinopathy (DR) is a complication of diabetes that can lead to blindness if untreated (Watkins, 2003). Patients who have diabetes must undergo frequent screenings that are limited by resources and can put high strain on patients and ophthalmologists. DR is classified as either non-proliferative (NPDR), which is characterized by lesions such as microaneurysms (MAs) and exudates, or proliferative (PDR), in which neovascularization of weak blood vessels occurs (Yun et al., 2008). More accurate systems would allow DR to be diagnosed early, such that patients can undergo treatment and avoid blindness. Manual diagnosis has difficulty meeting the eighty percent sensitivity that is recommended in Britain, and less developed areas particularly suffer from an imbalanced patient-to-specialist ratio. Studies estimate that by twenty years after diabetes onset, nearly all of patients with type I diabetes and sixty percent of those with type II diabetes will have DR.

Automated processing techniques have risen to prominence to address issues in DR classification, enabling screening to distinguish those who require further referral from those who are classified as low-risk. Machine learning (ML) algorithms extract image features which are feed into statistical classifiers (Litjens et al., 2017). Pattern recognition is facilitated using training sets, which allows the algorithms to optimize decisions

in the high-dimensional feature space. Systems vary in the level of hand-crafted features. Deep learning (DL) processes, most notably Convolutional Neural Networks (CNNs), determine the features and rules that optimize classification accuracy with minimum handcrafted components (Krause et al., 2018a).

Treatments such as laser surgery (i.e. panretinal photocoagulation) or intravitreous injections of anti-vascular endothelial growth factor provide effective means of halting vision loss from DR or diabetic macular edema (DME) if the disease is detected sufficiently early; however, many individuals cannot undergo timely screenings due to limited resources in personnel and technology (Williamson, Keating, 1998, Wong, Bressler, 2016). Traditional imaging methodologies rely on expensive or non-transportable technologies and thus limit a non-local approach to DR screening and diagnosis (Williamson and Keating, 1998). Therefore, the rise in digital cameras and scanning ophthalmoscopes have increased the feasibility of a telemedicine approach to addressing DR. Under such a system, digital images can be transported to remote or cloud-based storage systems for subsequent review. However, this increasing availability would also be likely be accompanied by reduced image quality and image field-of-view (FOV). This, along with limitations in expert personnel, increases the need for computer-aided diagnostic (CAD) systems.

The 1990s saw the first modern advances in DR diagnosis and grading with the introduction of a new clinical standard in the ETDRS scale (ETDRS Research Group, 1991) and the results of artificial neural networks (ANN) in DR detection (Gardner, Keating, Williamson, Elliott, 1996, Williamson, Keating, 1998). Interestingly, ANNs seemed to fall in popularity in this space in the early 2000s. Rather, processing methods focused more on image processing methods and different statistical classifiers. This may have been due to a belief that the current NNs were insufficient for detecting specific features of DR, like DR lesions (Lee et al., 2001). Many methods strayed away from image-level diagnosis during this time. This may perhaps be due to a fear that NNs learn risk factors of DR (Fig. 1), or even meaningless features, rather than the underlying disease (Wong and Bressler, 2016). At the same time, digital imaging and other

rapid screening tools have also heightened the prevalence of statistical and machine learning classifiers in this space, as in Bayesian, Mahalanobis, KNN, SVM, and other systems (Ege et al., 2000).

Deep learning systems rose to prominence in the computer vision space with the success of AlexNet and the ImageNet challenge (Krizhevsky et al., 2012). In particular, Google's work in DR classification and grading shifted the focus of this space to deep learning algorithms (Gulshan et al., 2016a). Recent works show potential for taking DR prediction in increasingly complex and clinically relevant directions. For instance, a recent work in Nature achieved promising results to pave the way for longitudinal DR prediction and tracking (Arcadu et al., 2019). Despite these advances, there has been slow progress in terms of the acceptance and implementation of these systems in widespread use. The United States Federal Drug Agency (US FDA) only approved the first AI system for DR detection, IDx-DR, in 2018 (Stark). Even so, the system's approval was limited in use. For example, those with other eye diseases or severe DR were not included in its approved use cases.

Researchers must consider the advances in DR imaging methodologies when designing appropriate AI systems for DR diagnosis and grading. The golden standard for DR detection has traditionally been the ETDRS seven standard fields (Aiello et al., 2019). This standard uses seven 30-degree stereoscopic images that encompass the optic disc, macula, area temporal to the macula, and the four vascular arcades (Li et al., 2011). While this method correlates well to DR detection, it only covers approximately a 75-degree field-of-view (FOV) and was established before digital fundus imaging was possible (Bae et al.). In fact, a recent study on ultra-wide field photography (above 200 FOV) found that at least 0.11 of eyes with DR may be at least two stages more severe than that found using the ETDRS standard (Aiello et al., 2019). This is likely due to the importance of the peripheral retina in detecting retinopathy signs like microvascular abnormalities, neovascularizations, vessel leakage, and nonperfused areas (Rabiolo et al., 2017). Therefore, there has been increasing evidence that diagnostic systems need to compensate for a

wider view of the retina, particularly in grading tasks. Currently, retinal specialists primarily diagnose DR on the basis of color stereographic photography, fluorescein angiography, and optical coherence tomography (OCT) (Cicinelli et al., 2019). However, new technologies, such as fundus autofluorescence and OCT angiography (OCTA), are emerging as interest areas in the field. These technologies, and compatible computer-aided diagnostic (CAD) systems, show great promise for capturing the intricacies of the disease. At the same time, an increasing need for DR screening in lower access areas has raised an interest in use of lower quality imaging devices. This movement has correlated to increase interest in CAD systems that compensate for lower FOV (i.e. single field, 20-50 FOV) with technologies such as image stitching and montage (Palacios et al., 2019).

Our survey differs from past work, as we include novel DL pipelines, overview imaging and ML processes, and discuss all tasks for grading DR (i.e. optic disc, blood vessels, lesions, and grading). This discussion facilitates clinical implementation of state-of-the-art systems. Our inter-disciplinary material will provide one source for research teams to find and understand these systems. Ultimately, DL frameworks offer particular promise for customizable and patient-specific diagnostic and therapeutic care. Section 2 overviews current resources for studying DR. Sections 3 and 4 describe the imaging modalities and automated frameworks for retinal imaging and classifying DR, respectively. Finally, Section 5 outlines different methodologies that address aspects of DR detection and grading, and Sections 6 and 7 provide our insights.

## Datasets

- •
  - Fundus Image Registration (FIRE) - includes 129 fundus images and a total of 134 image pairs. These data form three subsets according to visual characteristics. The files contain the image pairs and the corresponding ground truth, a binary color region of interest (ROI) mask, and a features ROI mask.
  - •

Structured Analysis of the Retina (STARE) - download all 400 raw images or in sets of 100. The corresponding diagnoses can be accessed separately in a.txt file. Another zip file contains the

## **General single-field imaging**

Single-field fundus images capture the optic nerve and macula under 20–50 degrees of FOV. Use of this method relies on the assumption that they capture the most prevalent pathologies, but this method risks missing important fundus lesions within the periphery (Witmer and Kiss, 2013). Traditional systems rely on single-field montages, with seven standard 30-degree images from the Early Treatment Diabetic Retinopathy Study (ETDRS) representing the standard for DR detection since 1991 (

## **Image processing**

Image processing methods address limitations in DR screening that emerge due to image quality, an imbalance in patients-to-specialists, and inter-grader inconsistencies (Winder et al., 2009). Grading images for DR is performed through pattern recognition, but features such as microaneurysms, hemorrhages, and exudates can be difficult to distinguish from the background retina. Processing steps may include normalization of sharpness and illumination, contrast enhancement, and noise and artifact

## **Optic disk (OD) segmentation**

OD removal improves bright lesion detection due to the maximum intensity values that frequently occur within this region (Lowell et al., 2004). Also, the OD rim may impact blood vessel detection. Alternatively, OD localization may contribute to blood vessel segmentation, as the major retinal vessels branch off from the OD. Lastly, the OD might be located to establish distance to the fovea. Maculopathy, or retinopathy of the macula, is particularly damaging due to the high visual importance of

## **Discussion**

DR encompasses a wide range of possible lesions, defects, and defect locations that presents a unique challenge to effective diagnosis. Lesion detection algorithms particularly emphasize MA detection as a typical indication of early DR, such that the disease can be diagnosed before significant eye damage occurs. However, detection of specific lesion types sacrifices effective DR grading - such grading could heighten standard of care and provide options to individuals in later stages of disease

## Conclusions

Diabetic Retinopathy represents a high-risk complication of diabetes that can lead to irreversible blindness without proper treatment. Proper artificial intelligence (AI) systems offer high potential in facilitating expedited detection and relevant care for individuals who suffer from this disease. Early detection systems benefit highly from a focus on mild DR symptoms, notably MAs, leading to a prevalence of such works in this area. Faster and less computationally expensive algorithms also

## Declaration of Competing Interests

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

The authors declare the following financial interests/personal relationships which may be considered as potential competing interests:

## CRediT authorship contribution statement

**Skylar Stolte:** Writing - original draft, Writing - review & editing, Investigation, Formal analysis. **Ruogu Fang:** Conceptualization, Supervision.

# Amazon Comprehend Medical

## Extrair informações de textos médicos não estruturados com precisão e rapidez

Extraia informações médicas de textos médicos não estruturados, como anotações médicas, relatórios de ensaios clínicos ou relatórios de radiologia

Identifique relacionamentos entre informações de saúde extraídas e vincule a ontologias médicas como ICD-10-CM, RxNorm e SNOMED CT

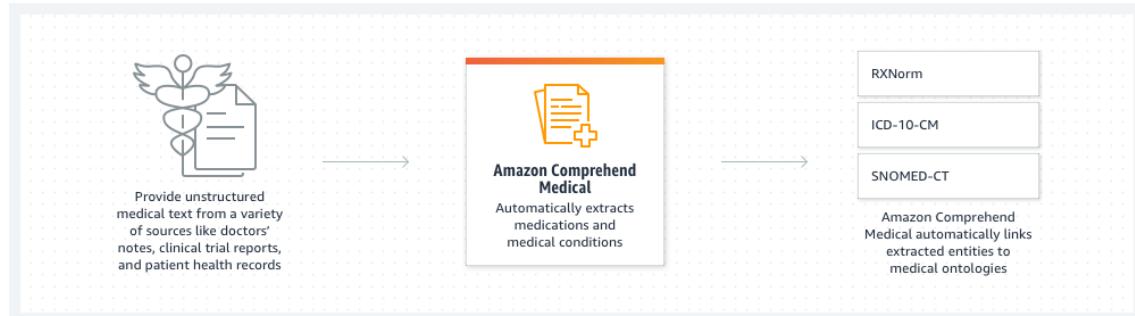
CTAutomatize e reduza o custo de processamento e codificação de texto médico não estruturado com APIs fáceis de usarSNOMED CT

Automatize e reduza o custo de processamento e codificação de texto médico não estruturado com APIs fáceis de usar

Implemente soluções de privacidade de dados do paciente e identifique informações de saúde protegidas (PHI) com um serviço qualificado para HIPAA

## Como funciona

O Amazon Comprehend Medical é um serviço de processamento de linguagem natural (NLP) qualificado para HIPAA que usa machine learning pré-treinado para entender e extrair dados de saúde de textos médicos, como prescrições, procedimentos ou diagnósticos.



[Clique para aumentar](#)

## Casos de uso

Acelerar o processamento de sinistros de seguros

Automatize os fluxos de trabalho de captura, validação e aprovação de sinistros para empresas de seguro de saúde para acelerar e simplificar o processamento de sinistros.

### Melhorar a saúde populacional

Analise dados não estruturados de saúde da população para melhorar os resultados de saúde, como identificar lacunas no atendimento e melhorar a eficiência do hospital.

### Escalar e acelerar a farmacovigilância

Identifique rapidamente os efeitos adversos de produtos farmacêuticos para melhorar a segurança dos medicamentos e atender aos requisitos regulatórios.

### Realizar análises de coorte médicas

Selecione o grupo certo de pacientes para testes clínicos para permitir uma seleção de pacientes mais rápida e precisa e custos mais baixos.

## Multimodal Data Analysis with AWS Health and Machine Learning Services

In this blog, we show how you can leverage AWS purpose-built health care and life sciences (HCLS), machine learning (ML), and analytics services to simplify storage and analysis across genomic, health records, and medical imaging data for precision health use cases. The included reference architecture is built on [AWS HealthOmics](#), [AWS HealthImaging](#), and [AWS HealthLake](#) services which enable you to store these data modalities with a few clicks. You can also create governed databases and tables via [AWS Lake Formation](#), that allows querying across multiple modalities using [Amazon Athena](#). You can then build, train, and deploy ML models with [Amazon SageMaker](#) to make real-time, personalized inference on patient outcomes. Finally, you can build custom, interactive dashboards to visualize multimodal data across individual patients and cohorts using [Amazon QuickSight](#).

HCLS customers are seeing a rapid growth in patient-level data. This data is increasing both in size and diversity, with modalities that include genomic, clinical, medical imaging, medical claims, and sensor data. While multimodal data offers a comprehensive view that can improve patient outcomes and care, analyzing multiple modalities at scale to build precision health applications is challenging. First, each modality requires distinct storage infrastructure, like Fast Healthcare Interoperability Resources (FHIR) for clinical records, Digital Imaging and Communications in Medicine (DICOM) for medical imaging, and custom databases for genomic variant and annotation data in Variant Call Format (VCF)

files. Second, not all storage modalities are accessible via common query languages like SQL, making it difficult to execute analytical queries across data types. Third, tooling for data science and machine learning is typically not built to handle the domain-specific data infrastructures or data types presented by these modalities, thereby hindering comprehensive analytics. Finally, customers wishing to pilot precision health initiatives have difficulty accessing a coherent dataset across all modalities with enough data points to support ML development and benchmarking.

Here, we show how AWS addresses these challenges and simplifies and accelerates the use of multimodal datasets in HCLS. To do this, we demonstrate importing, querying, and training ML models using the [Synthea Coherent Data Set](#), a fully synthetic dataset from MITRE available via the [AWS Open Data](#) program. This dataset provides FHIR resources, DICOM images, and genomic data with coherent linking across all modalities for patients diagnosed with cardiovascular disease. For further details, refer to the [Guidance for Multi-Modal Data Analysis with Health AI and ML Services on AWS](#) and the associated [code repository](#) which includes several example notebooks covering each section of the framework.

## Benefits of end-to-end multimodal data analysis

Healthcare customers today often face two challenges with their data. First, they have vast amounts of data from years of encounters that is rich with insights that they want to use for machine learning, advanced analytics, and improving patient outcomes. However, such data is often separated in organizational silos, stored in different formats, duplicative, and non-coherent. Second, they want to make their data actionable. Using historical healthcare data for training models or finding historic trends is important, but customers often want to use those insights with patients in their facilities today, not yesterday. This means using real-time data, and requires a way to securely store and manage real-time data for their organizations using purpose-built data stores optimized for the type, scale, and velocity of those data modalities.

Importantly, each data modality has its own special considerations for how to transform and store it to optimize analytical queries and be ML-ready. Data scientists and engineers can spend months on one modality developing custom extract, transform, and load (ETL) processes, data harmonization, and data warehouse design. Working with multiple modalities simultaneously increases

complexity by orders of magnitude, adding cost in terms of time and development effort.

With storage and analytics in AWS that is purpose-built for key HCLS data modalities (health records, genomic variants, medical imaging), you can go from raw data to training ML models with a few clicks and in minutes instead of months. AWS removes the undifferentiated heavy lifting needed to ingest, secure, query, and analyze across these data at scale.

## **AWS Health, machine learning, and analytics services and key capabilities**

AWS services overall are pay-as-you-go and there are no annual subscriptions or upfront costs to get started. AWS HealthOmics, AWS HealthImaging, and AWS HealthLake are purpose-built managed services for health and life sciences use cases that offer “zero-ETL” data stores – simply provide your data in its raw form (VCF, DICOM, FHIR), start an import job, and be able to query and analyze the data in minutes. Unlike on-prem or traditional data center deployments, there is no upfront planning required on how much storage to reserve or how you plan to use the data. HealthOmics, HealthImaging, and HealthLake data stores scale according to your needs and provide easy access for downstream analysis.

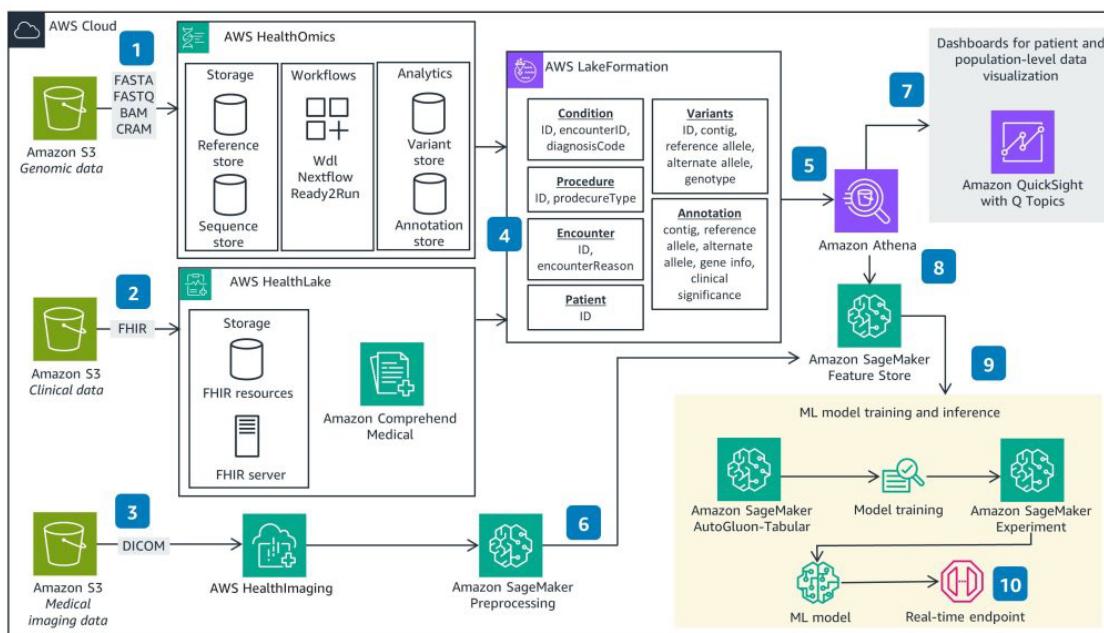
AWS HealthOmics enables you to transform genomic, transcriptomic, and other omics data into insights. AWS HealthImaging simplifies storing, transforming, and analyzing medical images in the cloud at petabyte scale. AWS HealthLake facilitates securely storing, transforming, transacting, and analyzing health records data in minutes for patients and populations. These services are designed to securely store and manage data from different modalities in a cost optimized and highly available environment. Each service provides a transactional layer (for real-time application needs) using APIs, as well as an analytics layer (for advanced querying and data analysis). Leveraging these services, either individually or together, simplifies HCLS data use in analytics, reporting, and other downstream applications.

You can securely access and govern these data and their corresponding purpose-built data stores in your AWS account’s data catalog via AWS Lake Formation which builds, manages, and secures data lakes. This makes multimodal data available for a wide

range of analytics services, like Amazon Athena, a serverless analytics service, that enables SQL queries on petabyte-scale data. For further downstream analysis, you can build, train, and deploy machine learning models on fully managed infrastructure with Amazon SageMaker. Finally, you can use Amazon QuickSight to unify and view trends and patterns in the data, by creating interactive data visualization dashboards that scale to hundreds of thousands of users without the need to set up, configure, or manage your own servers.

## Multimodal Analysis on AWS

In Figure 1, we present the architecture for building a scalable solution to ingest HCLS data from multiple modalities, manage data with purpose-built storage, preprocess data with managed services, create interactive dashboards for data visualization, and build ML models for actionable insights.



*Figure 1: Architecture for storing, integrating, and analyzing multimodal HCLS data with purpose-built services on AWS.*

In the following sections, we describe the high-level steps to realize this end-to-end multimodal analysis framework.

## Store data

First, ingest each data type from [Amazon Simple Storage Service](#) (S3) into the corresponding purpose-built AWS service (steps 1-3 of Figure 1).

Using the Synthea Coherent Data Set, we generated genomic, clinical, and imaging data ready for import into appropriate data stores provided by AWS HealthOmics, AWS HealthLake, and AWS HealthImaging. This includes genomic variants as VCF files for roughly 800 individuals, a human reference genome (FASTA file), genomic variant annotations from [ClinVar](#), FHIR R4 bulk data bundles for electronic health records (EHR) for about 1300 individuals, and 300 DICOM imaging study files. These data are publicly available in an S3 bucket named:

```
guidance-multimodal-hcls-healthai-machinelearning
```

Using AWS HealthOmics, the reference genome is imported into a [HealthOmics Reference store](#), VCF files into a [HealthOmics Variant store](#), and annotations into a [HealthOmics Annotation store](#). Using AWS HealthLake, the FHIR bulk data bundles are streamed or bulk-loaded into a [HealthLake data store](#). Using AWS HealthImaging, the DICOM files are imported into a [HealthImaging data store](#).

Note that each data store is purpose built for a specific data type, each aligning to standard data formats found in HCLS.

## Preprocess and analyze data

Once data is imported and any preprocessing needed is complete, you have tables for each modality in AWS Lake Formation that you link to databases and query for analysis (step 4 of Figure 1).

You can use Amazon Athena to run queries across data stores and extract relevant features from the tables stored in AWS Lake Formation (step 5 of Figure 1). This enables you to derive key information from multiple modalities at once and get a more comprehensive view of patients. You then store the features identified by your multimodal data queries in a SageMaker Feature Store using [FeatureGroups](#) (step 8 of Figure 1) which are used to train and test ML models.

When HealthImaging stores DICOM files, it extracts metadata like patient, imaging study, or series information from the file header to simplify search. You can also extract important image features by

processing the ImageFrame data (pixels) associated with each DICOM file. To get this data at scale, use the HealthImaging [GetImageFrame](#) API. For example, you can use the [AWS SDK for Python](#), the [Pyradiomics](#) package, and [Amazon SageMaker Preprocessing](#) to retrieve pixel information and apply a [Medical Open Network for AI](#) (MONAI) segmentation model to generate radiomic features. These features are also stored in a [SageMaker Feature Store](#) for further analysis (step 6 of Figure 1).

## Build, train, and deploy machine learning models

You can use Amazon SageMaker to build, train, and deploy ML models to derive further insights from multimodal data. For example, using multimodal features stored in SageMaker Feature Store, we trained a model that predicts the occurrence of stroke, hypertension, coronary heart disease, and Alzheimer's disease for patients diagnosed with cardiovascular disease (step 9 of Figure 1). To do this, we used [Autogluon](#), an AutoML algorithm offered by Amazon SageMaker, that trains a multi-layer stack ensemble model for classification and regression tasks. We then deployed the trained model as an endpoint for real-time or batch inference on the test dataset (step 10 of Figure 1). Overall, we found that models trained on features from all three data types (genomics, imaging, clinical) resulted in [higher predictive capability](#) compared to model trained on only a single data type.

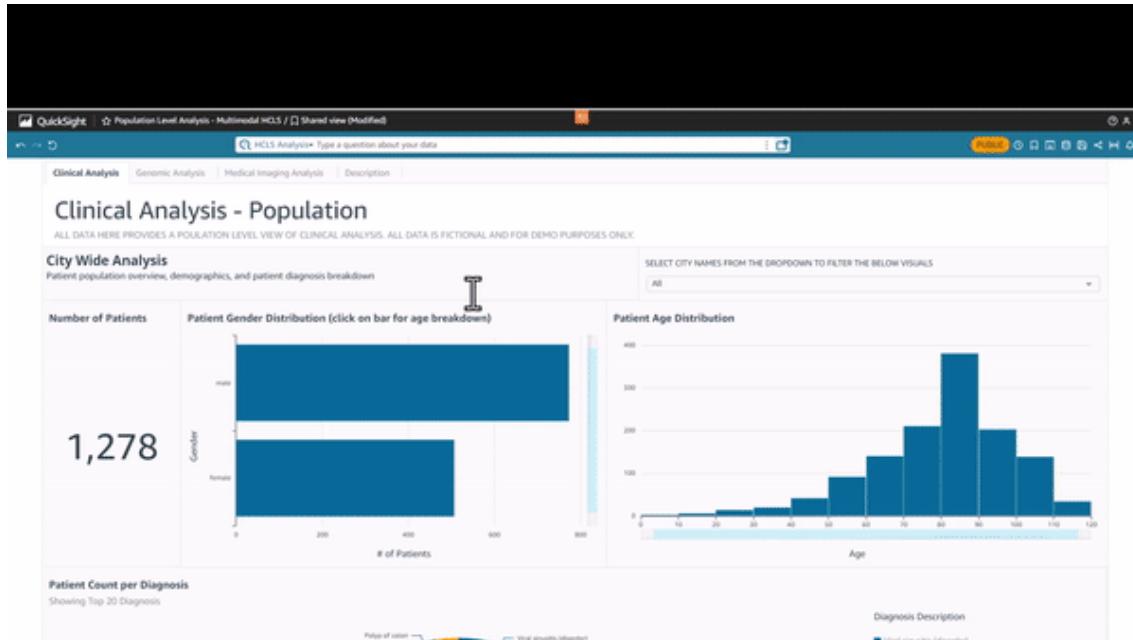
## Visualize data

Data visualization dashboards provide visual interfaces that stakeholders like clinicians, bioinformaticians, and radiologists can use to identify and interpret trends, patterns, and outliers in patients' data. You can unify diverse data types and build interactive dashboards with Amazon QuickSight (step 7 of Figure 1).

Here, we built two dashboards – one for population-level analysis and another for patient-level analysis – each using data combined from AWS HealthOmics, AWS HealthImaging, and AWS HealthLake.

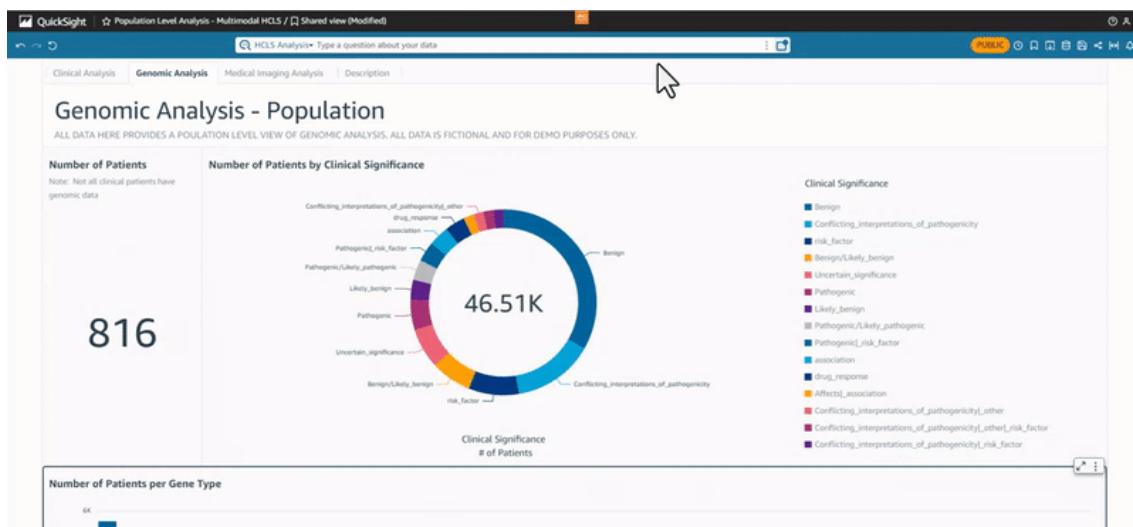
The [dashboard for population-level analysis](#) is for practitioners across different domains (eg. clinicians, bioinformaticians, radiologists), to get a comprehensive view of patients at the population or cohort-level. It includes the following:

**Clinical Analysis** – This provides an overview of clinical data of patients at the population level, including their demographic information, encounters, diagnosis, procedures, and insurance claims.



*Figure 2: Population-level data visualization dashboard for clinical data.*

**Genomic Analysis** – This provides an overview of genomic data at the population level, including types of genes, clinical significance of those genes, and distribution of cases.



*Figure 3: Population-level data visualization dashboard for genomic data.*

**Medical Imaging Analysis** – This provides an overview of medical imaging data at the population level, including first-order statistics describing the distribution of voxel intensities within the image region segmented by the MONAI model.

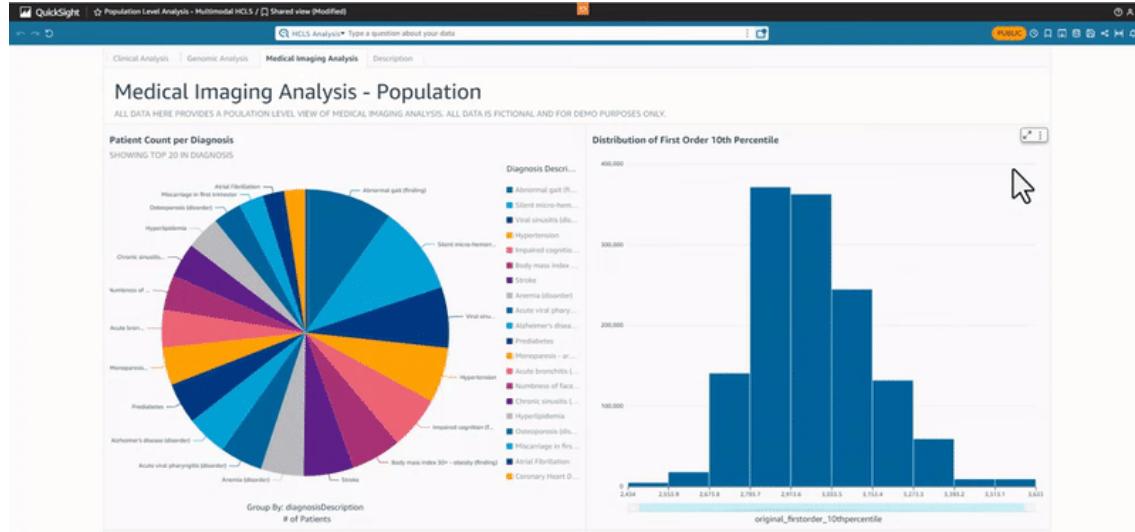


Figure 4: Population-level data visualization dashboard for imaging data.

The [dashboard for patient-level analysis](#) offers a single, interactive visual interface to help clinicians get a complete view of a patient across multiple data modalities (clinical, genomic, and medical imaging). Selecting a Patient ID from the dashboard menu automatically filters the underlying data and generates visualizations across multiple data types.

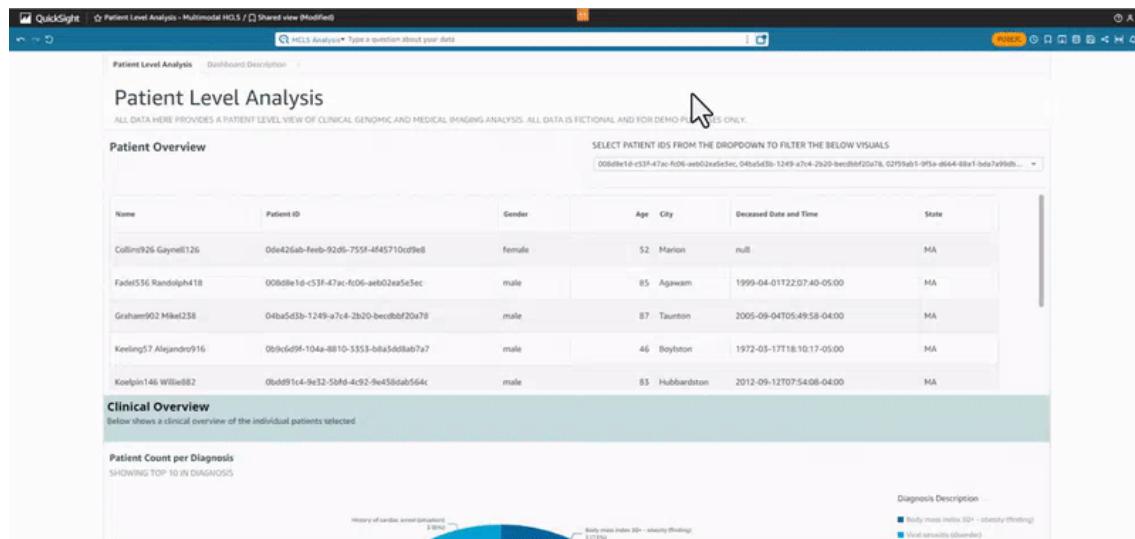


Figure 5: Patient-level data visualization dashboard for clinical data, genomic, and imaging data.

## Conclusion and next steps

In this blog, we show how you can easily store, process, and analyze genomic, health records, and medical imaging data using purpose-built AWS services to accelerate precision health.

With a few clicks, you have the resources you need to import data and perform integrative analyses across multiple data modalities. The concepts and service integration patterns provide a template that enables going from raw data to insights, like cohort identification and ML-assisted clinical decision support, within minutes. This template also mitigates the overhead of infrastructure design, maintenance, and management.

This easy-to-deploy, automated, and scalable framework can be extended to suit your specific needs. To try this out in your AWS environment, our example use case with the Synthea Coherent data set is available as an [open source GitHub repository](#). Within this repo are example notebooks that provide further technical details for [import operations](#), [data preprocessing](#), [model evaluation and benchmarking](#) and more.

To learn more about this end-to-end framework for multimodal analysis, check out our published [Guidance](#) in the [AWS Solutions Library](#).

TAGS: #healthcare, data visualization, genomics, machine learning, medical imaging, multimodal analysis

## AWS para Saúde e Ciências Biológicas

A AWS é o parceiro de tecnologia e inovação confiável para o setor global de saúde e ciências biológicas, que oferece confiabilidade, segurança e privacidade de dados incomparáveis.

Comece a usar a AWS

### Novo! E-book sobre saúde populacional

Com informações de EHRs, imagens médicas, reclamações, operações, estatísticas de saúde pública e muito mais, provedores, médicos e pesquisadores podem obter uma visão mais abrangente de um paciente. Baixe este e-book para saber como a AWS permite que você crie uma visão unificada do paciente que pode liberar todo o potencial dos dados de saúde populacional.

## Acelerar a inovação da bancada à cabeceira

As organizações de saúde e ciências biológicas estão reinventando a forma como colaboram, tomam decisões clínicas e operacionais orientadas por dados, permitem a medicina de precisão e reduzem

o custo do atendimento. Para ajudar as organizações de saúde e ciências da vida a atingir metas técnicas e de negócios, o AWS para Saúde e Ciências Biológicas oferece uma oferta de serviços da AWS e soluções de parceiros da AWS, usadas por milhares de clientes em todo o mundo.

Streamline innovation for healthcare providers with AWS (1:19)

Mais de 1.000

requisitos de compatibilidade global validados por terceiros

32

regiões da AWS para dar suporte de alcance global e soberania de dados

Mais de 50

iniciativas globais de genômica desenvolvidas pela AWS

Mais de 90

conjuntos de dados abertos sobre saúde, ciências biológicas e genômica

## Explore os serviços do AWS Health

### AWS HealthScribe

Gere anotações médicas automaticamente analisando conversas entre pacientes e médicos em suas aplicações.

[Saiba mais »](#)

### AWS HealthLake

Forneça uma visualização completa dos dados de saúde de indivíduos ou de populações de pacientes.

[Saiba mais »](#)

## AWS HealthImaging

Armazene, transforme e analise imagens médicas na nuvem em uma escala de petabytes.

[Saiba mais »](#)

## AWS HealthOmics

Transforme dados genômicos, transcriptônicos e outros dados ômicos em insights.

[Saiba mais »](#)

## Explore as soluções do AWS para Saúde e Ciências Biológicas



### Soluções de saúde

Aproveite as soluções criadas especificamente para transformar a saúde.

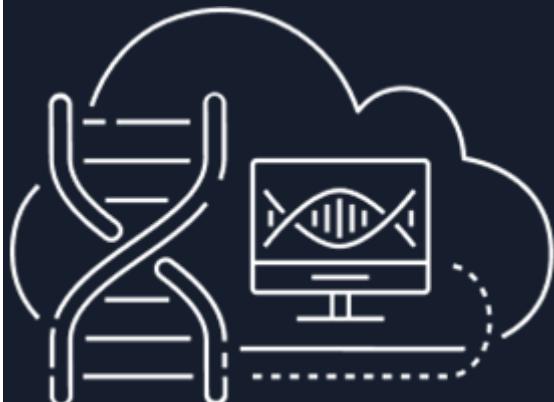
[Veja as soluções »](#)



### Soluções de ciências biológicas

Descubra soluções de ciências biológicas que ajudam você a levar a terapêutica ao mercado mais rapidamente.

[Veja as soluções »](#)



## Soluções genômicas

Faça avanços acontecerem com soluções genômicas que desbloqueiam insights.

[Veja as soluções »](#)

# Explore as iniciativas do AWS para Saúde e Ciências Biológicas

## AWS Health Equity Initiative

Crédito promocional da AWS e experiência técnica para organizações selecionadas que abordam disparidades de saúde que afetam comunidades carentes ou sub-representadas em todo o mundo.

[Saiba mais »](#)

## AWS Diagnostic Development Initiative (Iniciativa de Desenvolvimento de Diagnósticos da AWS)

Créditos promocionais da AWS e conhecimento técnico para organizações selecionadas em quatro áreas do programa: detecção precoce de doenças, diagnóstico, prognóstico e genômica de saúde pública.

[Saiba mais »](#)

## Medical Imaging on AWS Cloud-based platform for storage, sharing, and analysis

## AWS Healthcare Accelerator

Oportunidade de acelerador técnico, de negócios e mentoria de quatro semanas aberta a startups de saúde que buscam usar a AWS para ajudar a resolver os maiores desafios do setor de saúde.

[Saiba mais »](#)

## A AWS capacita saúde e ciências biológicas

Serviços e soluções de saúde desenvolvidos para propósitos específicos

Descubra novas maneiras de diminuir custos, melhorar a eficiência operacional e clínica e, por fim, aprimorar o atendimento ao paciente com soluções específicas que permitem organizações de saúde e ciências da vida de todos os tamanhos.

Rede de parceiros de saúde confiáveis

Alcance a inovação mais rapidamente com uma extensa rede de parceiros da AWS líderes do setor e o AWS Marketplace, que é um catálogo digital com curadoria de software, serviços e dados de terceiros que facilita os primeiros passos na AWS.

Especialistas na interseção entre saúde e tecnologia

Trabalhe com uma equipe de especialistas dedicados do setor de saúde e ciências biológicas que podem apoiar os seus programas de transformação digital e inovação. Os líderes da AWS health têm uma média de 18 anos de experiência no setor.

Segurança e confiabilidade líderes do setor

Eleve seu procedimento de segurança e simplifique a conformidade com mais de 130 serviços qualificados para HIPAA. Na AWS, você se beneficia da escala e da confiabilidade da mais ampla infraestrutura de nuvem global.

## A Philips utiliza a AWS aproveitar o poder da IA para médicos e pacientes

Veja a jornada da Philips com a AWS, desde o uso de dados e análises para potencializar a medicina de precisão com genômica na AWS, até a utilização da AWS para aproveitar o poder da IA para médicos e pacientes e a criação de sua plataforma HealthSuite

na AWS para permitir escalabilidade, maior rapidez no lançamento no mercado e conformidade simplificada de privacidade e segurança para soluções inovadoras de saúde e ciências biológicas.

[Saiba mais »](#)

## **Medical Imaging on AWS Cloud-based platform for storage, sharing, and analysis**

**INTRODUCTION** Amazon Web Services (AWS) and our partners have solved image management, for X-rays, CT scans, MRIs, and ultrasounds, in the cloud with four primary pillars that work in unison to benefit the healthcare system and its patients. In this eBook, dive deep on the AWS solution for storing and sharing medical images that has transformed how healthcare systems deliver patient care.

**PILLAR #1** Accessing enterprise imaging solutions on AWS Before 1895, physicians could not see inside a patient's body without an invasive medical procedure. That year, German mechanical engineer Wilhelm Conrad Roentgen discovered what he called X-rays while experimenting with electron tubes. Roentgen used the new technology to photograph his wife's hand, revealing its skeletal structure. Medical professionals peered inside the human body for the first time, and the field of medicine transformed. Now, nearly 130 years later, the field of medical imaging has evolved incredibly. CT scans create computerized, 360-degree images of the human body in incredible detail within minutes. Many different types of medical images, ranging from X-rays to CT scans, play a critical role in patient health outcomes, including wellness visits, disease prevention, early detection, diagnosis, prognosis, treatment, follow-ups, and research. But the technology for image sharing has not kept pace with the technology for image capture.

Many clinicians, including radiologists and cardiologists, rely on Picture Archiving and Communication Systems (PACS) to view, share and reference images for various procedures and to determine treatment plans. PACS is a digital system for storing and sharing medical images and reports. Unfortunately, PACS is often unavailable or difficult for physicians to access, forcing them to find workarounds to obtain the information they need to do their jobs. Some hospitals still burn CDs in order to make images available to

interventionalists, and many patients find themselves acting as a delivery service, driving to imaging centers to pick up copies of CDs and hand-delivering them to their specialist or PCP. Too many patients and physicians live and work as if the year is 1990. Patients sometimes end up getting multiple rounds of the same imaging and the associated exposure to radiation—simply because specialists struggle to gain access to previously captured images held at different locations. This results in lost time and money; it also adds unnecessary radiation exposure. In fact, multiple institutions say they will only consider vendors with cloud solutions because their patients and physicians demand it. Solution PACS on AWS benefits patients and healthcare systems by lowering infrastructure costs, increasing accessibility, and allowing for remote access.

Enterprise Imaging on AWS is

- ◊ Accessible, featuring remote interpretation of images and patient access.
- ◊ Full-stack, featuring viewer, workflow, and VNA. Our Partners utilize AWS services such as Amazon HealthLake Imaging, Amazon Simple Storage Service (Amazon S3), Amazon Elastic Compute Cloud (Amazon EC2), Amazon EC2 G4 instances, and Amazon Elastic Block Store (EBS) to build PACS/VNA solutions in the cloud
- ◊ Fast, with sub-second image delivery, streamed on demand; the system setup is also easy and installs within days
- ◊ Flexible, deploying as software as a service (SaaS) or selfhosted, whichever your facility prefers
- ◊ Scalable, to support local, regional, and national health systems; clients can use elastic compute and storage resources as needed, paying only for what they use
- ◊ Secure, leveraging robust AWS security controls and enterprise-ready, read-only deployment architectures to protect against ransomware
- ◊ Multimodal, enabling comprehensive clinical depth with diagnostic and enterprise viewing and mobile imaging. No more forcing patients to hand-deliver images to their healthcare providers. It is the 21st Century.

Fast access and disaster recovery (DR) of medical histories through VNA Digital security entails a number of measures, and information must be protected against unauthorized access, system overload, cyber-attack, and physical vulnerabilities. The challenge of

maintaining and updating data storage to safeguard against disaster with a rapidly expanding image set goes beyond physical storage capacity. Replacing and expanding hardware isn't just expensive and time-consuming—it creates additional risk. Every time you replace or copy hardware, you make your data vulnerable to loss, which decreases patient trust, damages your brand, and leads to serious legal and HIPAA ramifications. Additionally, recovery can take hours or days when data loss occurs, which is significant in the medical field, where every second counts.

Healthcare providers need easy, assured access to patients' medical histories and data at all times, which means protecting providers against blocked access due to inefficient systems. When historical imaging data is lost or inaccessible, it leaves physicians unable to track health conditions over time, which can result in medical oversight and error. The best systems protect data while simultaneously ensuring access for those who need it. Fast and secure access to healthcare records across facilities and teams improves patient outcomes due to comprehensive, coordinated care. Patients also support accessibility, with 81 percent of adults in favor of increased access to health information for patients and providers. In short, storing data in a single, on-premises location puts it at increased risk of loss and fails to prioritize fast recovery and authorized, easy access. When facilities store medical images using nonstandard file types and software, it creates time-consuming and frustrating obstacles for physicians outside the initial organization who need to access them. For example, another block to access that occurs with on-premises systems is asynchronous data viewing. With many on-premises systems, a single party logging in and accessing patient medical files prevents any other party from accessing it simultaneously. Meanwhile, the best healthcare requires a medical team.

A VNA, or vendor-neutral archive, clears this obstacle. VNA is a system in which medical professionals archive images and data in a standard format for easy access across systems. When this system was implemented at a large healthcare network in Ohio, the impact was remarkable. The process was associated with more than 10 percent cost savings, a 30 percent reduction in storage costs, superior support for disaster recovery, and an 80 percent decrease in unscheduled outages. All these were achieved despite a 120 percent increase in archive retrieval needs and a 40% growth in image production. Furthermore, cloud-based VNA storage with AWS can consist of a data lake in which all data is stored in a centralized

location. By consolidating data in one place, an AWS data lake serves as a starting point for large-scale analytics of big data in high-performance computing environments, as well as artificial intelligence (AI) and machine learning (ML). Using a data lake thus enables AI and ML to gain efficiencies and insights, improving the overall system. We'll explore that a little later in Pillar 4.

**Solution** VNA and cloud storage is the modern data architecture that enables your organization to protect and access data, improving patient lives, optimizing operations, and boosting clinician satisfaction.

AWS disaster recovery Amazon HealthLake, the AWS data lake for healthcare, is a managed service protected by AWS global network security procedures. AWS's global infrastructure is built around AWS Regions and Availability Zones. AWS Regions provide multiple physically separated and isolated Availability Zones, which are connected with low-latency, highthroughput, and highly redundant networking. With Availability Zones, you can design and operate applications and databases that automatically fail over between zones without interruption. Availability Zones are more highly-available, fault-tolerant, and scalable than traditional single or multiple data center infrastructures. Amazon HealthLake helps you keep pace with evolving disaster recovery (DR) strategies without costly physical updates and reduces downtime and data loss with its fast, reliable recovery. AWS DR services can decrease your recovery point objective to seconds and your recovery time objective to just a few minutes. You can quickly recover operations after unexpected events, such as software issues or data center hardware failures.

**Case study King Hamad University Hospital (KHUH)** KHUH and Bahrain Oncology Center is a 600-bed hospital in Bahrain. Over the years, KHUH faced constraints with the exponential growth of their on-premise digital storage needs, particularly with the medical images housed by their picture archiving and communication system (PACS). Storage upgrade activities tied up IT personnel and took efforts away from KHUH's core healthcare business and patient-centric focus. As a result, KHUH wanted a long-term archival solution that could grow and adapt automatically. Furthermore, the solution required minimal changes to the existing PACS system, as an independent software vendor (ISV) provided the PACS system,

**and changes to the software code base required too much time to implement. KHUH turned to AWS to find a solution, leveraging Amazon S3 File Gateway and Amazon S3 Glacier to store medical images in the cloud for long-term archiving without making changes to the existing PACS. In their new storage architecture, only medical images generated within the last four years are kept on-premises, while the remaining data is archived with AWS. At KHUH, medical imaging data is now both securely stored and available to authorized professionals using VNA. In the event of a disaster, their database and recovery systems will enable fast access to medical histories, prioritizing the patients at the center of their mission.**

**PILLAR #3 AI-based medical imaging research** Medical teams rely on pathologists to examine bodies and body tissues for various reasons, including disease prevention, early detection, diagnosis, treatment plan development, and research. Pathologists are responsible for analyzing massive amounts of image data, and inevitably, the potential for human error increases with fatigue, stress, and workload. As researchers have searched for ways to optimize image analysis, AI and ML offer great potential.

In recent years, medical teams have implemented artificial intelligence (AI) and machine learning (ML) to analyze medical images that can identify patterns and characteristics to support diagnosis and prognosis, improve care, and aid research. Using this technology enables the medical field to process massive amounts of data without the fatigue or potential for error of human eyes, and with incredible attention to detail, according to recent studies. The AWS solution allows users to ◊ Accelerate their research ◊ Set up reproducible workflows ◊ Scale infrastructure up and down ◊ Set up multimodal ML pipelines ◊ Gain financial flexibility ◊ Benefit from research funding programs

AWS AI/ML offers many opportunities to level up.

- ◊ Our AI/ML services enable users to explore more architectures, hyperparameters, and hypotheses than what is possible with just static on-prem infrastructure, which supports accelerated research.
- ◊ Services such as Amazon SageMaker allow software engineers to create, program, and deploy machine-learning models in the cloud.

- ◊ AWS can help you set up reproducible workflows. This is important if you need to undergo an approval process to bring your model into a clinical production environment.
- ◊ Our underlying infrastructure standardization means you can scale your operation up and down as research requires.
- ◊ With AWS, you can set up scalable ML pipelines for multimodal data, allowing you to examine medical imaging in the context of other EHR data for better patient outcomes. This is ideal for precision medicine teams who are increasingly handling heterogeneous workloads.
- ◊ The pay-as-you-go pricing model allows you to trade capital expenses for variable expenses, an option many finance leads opt for as OPEX approvals are often easier to get.
- ◊ You can benefit from different precision medicine and data-sharing funding programs and the architecture best practices we provide.

**Case study Grand Challenge at Radboud University Medical Center** Radboud University Medical Center in the Netherlands partnered with AWS to launch Grand Challenge, a platform that allows users to build, test, and deploy imaging algorithms using ML. Currently, more than 70,000 researchers and clinicians are registered globally, with over 300 challenges and 1,000 algorithms deployed. Since they migrated the platform to AWS, it features scan time to load at <10ms latency. This functionality accelerates medical innovation by allowing developers worldwide to collaborate securely on research using AI and ML.

**PILLAR #4** Enabling a single, comprehensive view for safer, more efficient healthcare The medical field conducts over 5.5 billion imaging procedures annually, and this number continues to grow. Over the past decade and a half, the workload for radiologists in the United States has almost doubled—from 58 to 100 assignments per day. On top of that, image study size averages have reached 150 MB, further increasing the work and time required to analyze images. The issue with volume and mass is exacerbated by the insufficient systems used by many medical centers. Priority The proliferation of multiple copies of the same image datasets across clinical and research organizations, complicates operations, puts patients at risk, and costs facilities time, money, and other resources.A single copy of patient imaging data in the cloud

A single copy of patient imaging data in the cloud Reduce the cost of medical imaging storage by up to 40 percent with HealthLake Imaging. We started working backwards from our customer's needs around medical imaging, we discovered that there were multiple copies of the same procedure being stored on premise. For example, a 1GB CAT Scan procedure might be stored on the CT Scanner, Radiology PACS, Cardiology PACS, VNA, image sharing system, disaster recovery system and other specialty workstations. These copies are the side effect of the legacy DICOM protocol – now almost 30 years old – which uses a store and forward architecture. Not only do these extra copies increase storage costs, but they also increase the complexity with keeping everything in sync. AWS has a strong history of building highly scalable services and it became clear to us that we could eliminate these extra copies by providing scalable and fast access to image data. Amazon HealthLake Imaging enables you to store one copy of the image data and can reduce your TCO by up to 40 percent. Sub-second image retrieval from anywhere HIPAA-eligible and GDPR compliant. But cost is not the only consideration: Our customers also told us that clinicians must be able to view images as fast – or better – than they currently do with their on premises systems. Amazon HealthLake imaging contains additional innovation that can delivers sub second image access from anywhere in the world in the world in under a second, even on a smart phone. This is possible thanks to state-of-the-art lossless image compression technology and the high-speed low latency AWS global network infrastructure. Amazon HealthLake Imaging contains numerous innovations that enable to deliver images as fast – and in many cases faster – than existing PACS solutions.

A single copy of patient imaging data in the cloud Reduce the cost of medical imaging storage by up to 40 percent with HealthLake Imaging. We started working backwards from our customer's needs around medical imaging, we discovered that there were multiple copies of the same procedure being stored on premise. For example, a 1GB CAT Scan procedure might be stored on the CT Scanner, Radiology PACS, Cardiology PACS, VNA, image sharing system, disaster recovery system and other specialty workstations. These copies are the side effect of the legacy DICOM protocol – now almost 30 years old – which uses a store and forward architecture. Not only do these extra copies increase storage costs,

but they also increase the complexity with keeping everything in sync. AWS has a strong history of building highly scalable services and it became clear to us that we could eliminate these extra copies by providing scalable and fast access to image data. Amazon HealthLake Imaging enables you to store one copy of the image data and can reduce your TCO by up to 40 percent. Sub-second image retrieval from anywhere HIPAA-eligible and GDPR compliant. But cost is not the only consideration: Our customers also told us that clinicians must be able to view images as fast – or better – than they currently do with their on premises systems. Amazon HealthLake imaging contains additional innovation that can delivers sub second image access from anywhere in the world in under a second, even on a smart phone. This is possible thanks to state-of-the-art lossless image compression technology and the high-speed low latency AWS global network infrastructure. Amazon HealthLake Imaging contains numerous innovations that enable to deliver images as fast – and in many cases faster – than existing PACS solution

**Solution** Amazon HealthLake Imaging allows medical professionals to store, access, and analyze medical images in the cloud, at petabyte scale..

Take advantage of AWS's cloud-native imaging data platform for both clinical and research needs to unify silos of data Amazon HealthLake Imaging allows customers to build the next generation applications for enterprise imaging such as PACS and advanced visualization tools. For AI/ML use cases, customers can build solutions to build cohorts over their entire archive in hours – something that currently takes them weeks on premise. Amazon HealthLake Imaging also integrates with Amazon SageMaker for training and inference of medical imaging AI models, QuickSight for operational dashboards, and Amazon Redshift for analytics. Amazon HealthLake Imaging solves many of the obstacles t that are faced while developing medical imaging solution, by helping to make the process of uploading, storing, and accessing images automatic and effortless. To achieve this, the application converts and optimizes images for rapid retrieval on the web, desktop, and cell phone. Petabyte-scale cloud capacity means software systems can operate at increased scale while keeping the bottom line tight. Medical imaging storage costs up to 40% less with Amazon

HealthLake Imaging thanks to the enablement of its single, comprehensive, and up-to-date view of patient data. Amazon HealthLake Imaging also features image retrieval latencies of under a second and application interfaces operating in the cloud. In short, Amazon HealthLake Imaging offers a low-cost, high-performance and scalable solution to easily access medical image across the care continuum. Nothing is sacrificed, and patient care remains the priority. Summary of benefits: ◊ Enables a single view of patient history and imaging ◊ Creates one image data source for better clinical and research workflows ◊ Features 40% lowered TCO ◊ Boasts sub-second image access ◊ Automates infrastructure management ◊ Offers robust partner network ◊ Allows for enterprise imaging, AI/ML research, and long-term image archival

Take advantage of AWS's cloud-native imaging data platform for both clinical and research needs to unify silos of data Amazon HealthLake Imaging allows customers to build the next generation applications for enterprise imaging such as PACS and advanced visualization tools. For AI/ML use cases, customers can build solutions to build cohorts over their entire archive in hours – something that currently takes them weeks on premise. Amazon HealthLake Imaging also integrates with Amazon SageMaker for training and inference of medical imaging AI models, QuickSight for operational dashboards, and Amazon Redshift for analytics. Amazon HealthLake Imaging solves many of the obstacles that are faced while developing medical imaging solution, by helping to make the process of uploading, storing, and accessing images automatic and effortless. To achieve this, the application converts and optimizes images for rapid retrieval on the web, desktop, and cell phone. Petabyte-scale cloud capacity means software systems can operate at increased scale while keeping the bottom line tight. Medical imaging storage costs up to 40% less with Amazon HealthLake Imaging thanks to the enablement of its single, comprehensive, and up-to-date view of patient data. Amazon HealthLake Imaging also features image retrieval latencies of under a second and application interfaces operating in the cloud. In short, Amazon HealthLake Imaging offers a low-cost, high-performance and scalable solution to easily access medical image across the care continuum. Nothing is sacrificed, and patient care remains the priority. Summary of benefits: ◊ Enables a single view of patient history and imaging ◊ Creates one image data source for better clinical and research workflows ◊ Features 40% lowered TCO ◊ Boasts sub-second image access ◊ Automates infrastructure

management ◊ Offers robust partner network ◊ Allows for enterprise imaging, AI/ML research, and long-term image archival

## How to build a global, scalable, low-latency, and secure machine learning medical imaging analysis platform on AWS

by Bram van Ginneken, Razvan Ionasec, James Meakin, and Nuñez Pölcher | on 21 AUG 2020 | in [Amazon Machine Learning](#), [Customer Solutions](#), [Healthcare](#), [Healthcare](#) | [Permalink](#) | [Comments](#) | [Share](#)

### Introduction

It is hard to imagine the future for medical imaging without machine learning (ML) as its central innovation engine. Countless researchers, developers, start-ups, and larger enterprises are engaged in building, training, and deploying machine learning solutions for medical imaging that are posed to transform today's medical workflows and the future value of imaging in diagnosis and treatment.

To reach scientific breakthroughs, researchers need first to overcome several obstacles when training and deploying machine learning models. First, they must access large volumes of data stored in disjointed registries that are located in different parts of the world. Second, they need to deploy standardized tools globally to generate ground truth on reference datasets. Finally, they need to configure a secure and cost-effective environment to allow for collaboration between research groups.

That is why Diagnostic Image Analysis Group (DIAG) at the Radboud University Medical Center in Nijmegen, The Netherlands, turned to AWS to migrate their [grand-challenge.org](#) open-source platform from their on-premises data center to the cloud. [Grand-challenge.org](#) was established in 2012 for the organization of machine learning challenges in biomedical image analysis, and today brings together 45,000+ registered researchers and clinicians from all over the world to collaborate on creating novel ML solutions in the field.

When in early March 2020 it was hypothesized that CT imaging could play an important role in the diagnosis and assessment of COVID-19, the Dutch Radiological Society rapidly proposed a

standardized assessment scheme for CT scans of patients with suspected COVID-19 called CO-RADS. And radiologists turned to the [grand-challenge.org](https://grand-challenge.org) platform to collect imaging data and to use the platform's browser-based viewing system for CT scans to assess the performance of the CO-RADS model, which achieved a high discriminatory power for diagnosing COVID-19 from a CT scan alone (ROC 0.91, 95% CI, 0.85-0.97, for positive RT-PCR results)([1](#))

On the platform, DIAG has made the COVID-19 dataset, the training course to teach radiologists how to assess a scan using CO-RADS, the exam and the ML model available to all registered users. However, grand-challenge.org was running in an on-premises data center, and the experience of the radiologists using the course outside of Europe was poor due to latency of the server-side rendered viewing systems, and the number of scans DIAG could process with our AI tools was limited by the amount of hardware we provisioned before the emergence of SARS-CoV-2.

In April 2020, the collaboration between DIAG and AWS started to bring globally distributed browser-based viewing systems and elastic scaling to make these tools available to machine learning and clinical researchers worldwide. Through a successful collaboration between DIAG's Research Software Engineering team and AWS the grand challenge platform was able to be migrated to the cloud in less than two weeks from the start of the project. Several technical hurdles were overcome, resulting in a more robust, performant, and scalable application that will continue to support the medical imaging community during this pandemic and beyond.

This work presents the architecture and services used for the global medical imaging analysis platform and explains the challenges, solutions, and results obtained including 1) exchange data with the global research community, 2) low-latency and scalable web-based viewer, 3) secure and cost-effective deployment & distribution of machine learning models, and 4) Rapid migration to cloud of data and compute.

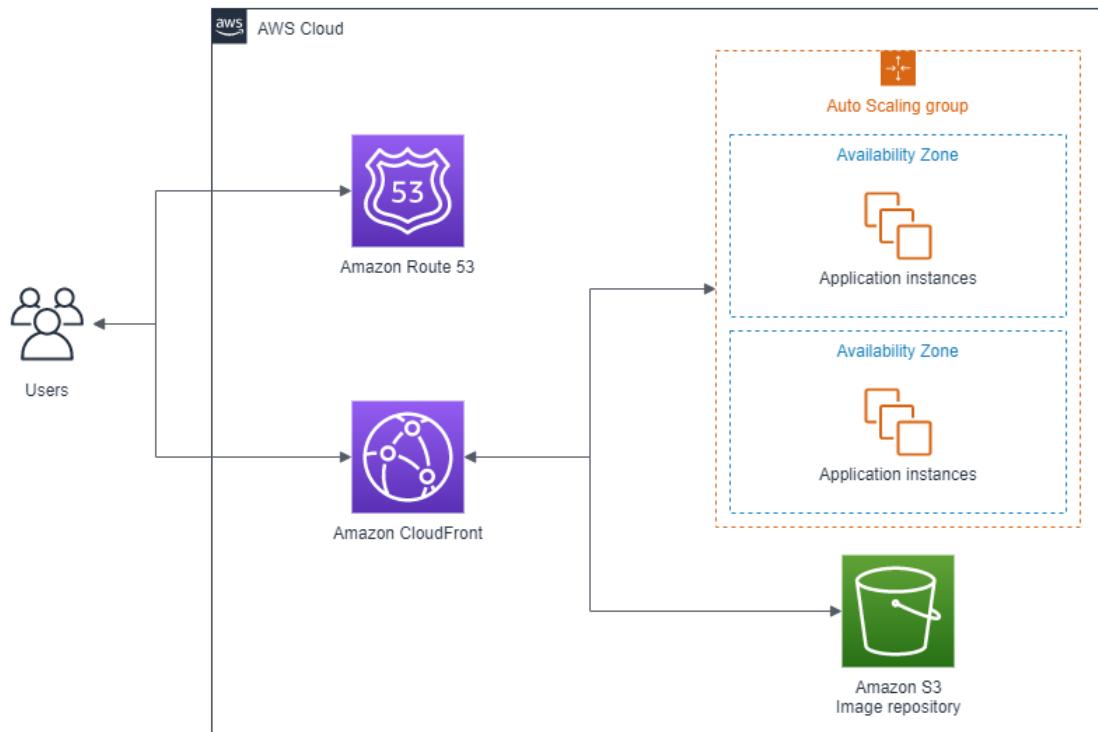
## **Exchange data with the global research community**

Developing robust machine learning solutions to problems in biomedical imaging requires access to large amounts of annotated training data. The volume of data generated by medical instruments such as MRI and CT scanners, next-generation sequencers, and digital pathology machines steadily increases as sensors become more accurate and systems more sophisticated in characterizing

physiology. The massive data generated is locked in siloed databases and proprietary formats. The exchange of data and collaboration on research projects beyond the boundaries of an institution remains a challenge from a technical as well as compliance and security perspective.

On grand-challenge.org DIAG has added functionality so that researchers can set up archives to easily share data with each other, apply algorithms to that data, and set up their own reader studies to invite experts to annotate the data. In medical imaging, shipping HDDs across sites is the norm, but AWS enabled the use of direct upload to Amazon Simple Storage Service ([Amazon S3](#)) with accelerated transfers to gather data from sites globally. Users are able to upload data in a variety of medical imaging formats including DICOM and a variety of whole slide image formats. These data are automatically validated and converted to Metalmage or TIFF as this is much easier for the machine learning researchers to work with.

Amazon S3 is used to store all of the imaging data on the grand-challenge.org platform. Now, DIAG does not need to worry about scaling the storage after the increased data influx from scans of patients with suspected COVID-19. To allow for fast access to the data we use Amazon CloudFront and easily integrate URL signing with the Django backend so that users are only able to download the files for the images that they have permission to view.



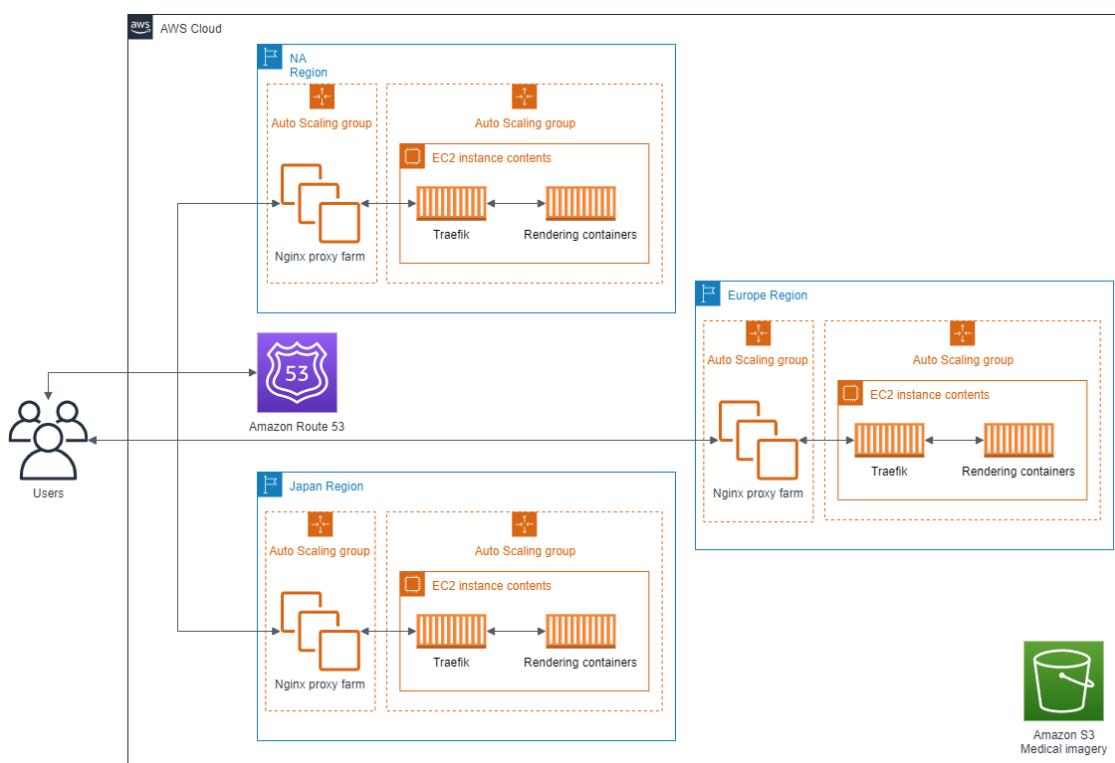
## Low-latency and scalable web-based viewer

Today, most viewing and processing of medical imaging data in both clinical and research environments happens on-premises on dedicated workstations capable of server-side rendering necessary for routine manipulations such as MIP (maximum intensity projection) viewing or 3D volumetric rendering. With the increased collaboration between radiologists from many institutions spread across the world as well as the rise in secondary usage of medical imaging for research and development of ML solutions, there is a need for globally available solutions. This very challenge was faced recently by Radboud University Medical Center in Nijmegen as they received great interest from radiologists worldwide for their CO-RADS Academy solution that teaches physicians how to read COVID-19 CT images.

The Diagnostic Image Analysis Group (DIAG) developed a web-based medical imaging viewer called CIRRUS, which is built on MeVisLab from MeVis Medical Solutions. CIRRUS enables the use of many tools that radiologists require for interacting with medical imaging data. Server-side rendering is used for rapid loading of the medical imaging data and allows the use of powerful rendering hardware for 3D multiplanar reformation, pre-loading of series in memory and GPU acceleration. The rendered scenes are streamed to the client over a WebSocket connection to a VueJS single page

application to also gain the strengths of client-side interactions where necessary. These workstations are deployed using Docker containers, and one container image is launched per user with the users being routed to their container instance with Traefik.

In this project, DIAG was able to set up rendering servers on AWS in Europe, Japan, and North America on Amazon Elastic Compute Cloud ([Amazon EC2](#)). To start the container on-demand for a new user, it takes less than 30sec and we are able to horizontally scale the compute pool by adding additional EC2 instances in each Region. The medical imaging data are stored in an Amazon S3 bucket in Europe. To ensure rapid loading times in North America and the Asia Pacific Regions we used [Amazon CloudFront](#) to cache the data on demand. The loading performance for a typical 300MB CT, 500 slices CT studies is less than 10 seconds. With a latency of 20ms, there is no observer delay in scrolling, which provides a great user experience.



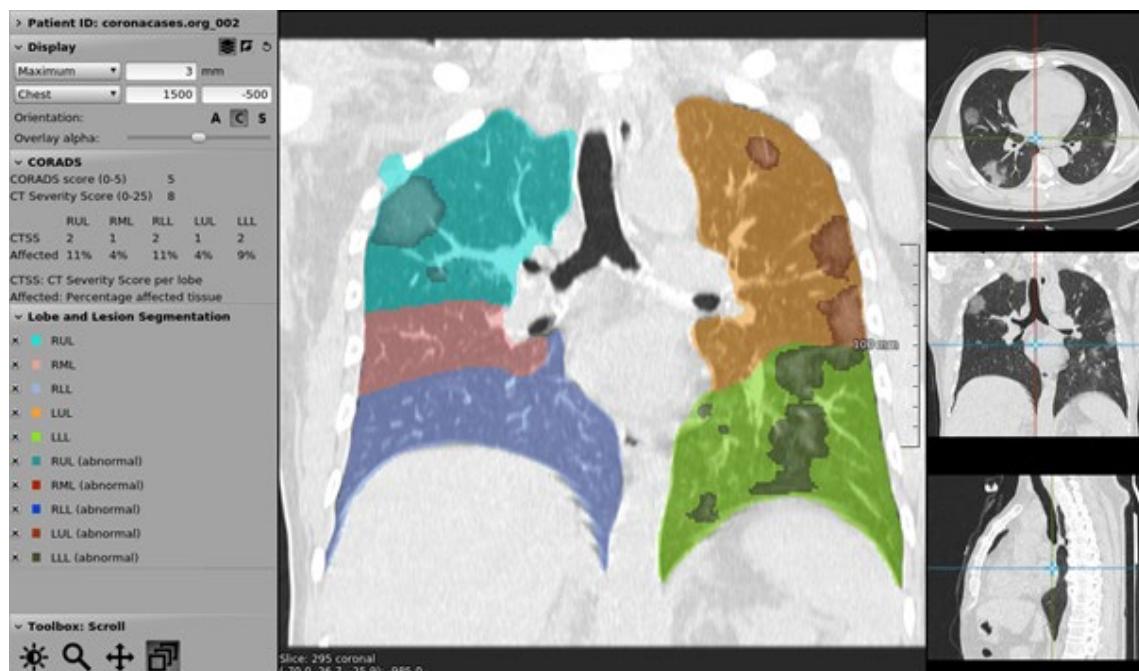
## Secure and cost-effective deployment & distribution of machine learning models

Researchers need to have the freedom to use whatever tool or library is most appropriate for their use case, and often find it difficult to distribute their models to the rest of the research community. On [grand-challenge.org](#) this gap is bridged by allowing researchers to

upload their developed model and pre-processing pipeline as a Docker container image, where they can manage the users who can access the algorithm. This allows researchers to share their algorithms with the community, where the platform will handle authentication, authorization, data access, validation and conversion of DICOM to Metalmages, and execution of the containers on the data with GPU acceleration.

The grand-challenge.org platform uses Celery to schedule the jobs for these containers and medical images, providing GPU acceleration where needed with NVIDIA T4 cards. DIAG was able to reduce the number of services it manages by using Amazon Simple Queue Service ([Amazon SQS](#)) as the message broker and can now horizontally scale by adding workers that listen to each queue. It is also able to run across its existing provisioned hardware and during periods of increased demand start extra g4dn EC2 instances.

This has enabled researchers to rapidly deploy a model for automated scoring of CT scans with CO-RADS and is available at <https://grand-challenge.org/algorithms/corads-ai/>. Users are able to upload their own data and receive a prediction on this data within 2 minutes, and then inspect the results in the globally available browser-based workstations.



*Image courtesy of Radboud University Medical Center in Nijmegen*

## Rapid migration to cloud of data and compute

DIAG had previously been running grand-challenge.org in its on-premises data center, and did not foresee the scale at which it would need to operate during this pandemic. However, when developing the application DIAG had the cloud in mind, and tried to ensure that workloads were mobile. The team at DIAG uses the 12 Factor App methodology, has robust CI/CD pipelines that distribute the application as a set of Docker images, provision bare metal and VM instances with Ansible, and used Minio to abstract the on-site storage with the Amazon S3 API.

Using AWS services, DIAG was able to rapidly move this workload to the cloud. Several terabytes of imaging data were synced in place using Amazon S3 sync, so that switching over the storage backend was a case of changing environment variables. The team was also able to move the database to a managed Postgres RDS instance and the Celery broker from Redis to Amazon SQS to reduce the ops burden. Moving this workload to AWS has allowed for scale on-demand, based on the unpredictable demand during this pandemic.

## Research results and future work

Recently, the group at Radboud University Medical Center together with numerous collaborators published the results of the CORADS-AI, a system that consists of three deep learning algorithms that automatically segment the five pulmonary lobes, assign a CO-RADS score for the suspicion of COVID-19 and assign a CT severity score for the degree of parenchymal involvement per lobe.<sup>(2)</sup> The system was tested on 105 patients ( $62 \pm 16$  years, 61 men) and 262 patients ( $64 \pm 16$  years, 154 men) internal and the external cohorts, respectively. The system discriminated between COVID-19 positive and negative patients with areas under the ROC curve of 0.95 (95% CI: 0.91-0.98) and 0.88 (95% CI: 0.84-0.93). [CORADS-AI](#) has been deployed on the AWS platform and it is now available for other researchers.

One of the future goals of grand-challenge.org is to allow users to submit their custom algorithms to run in GPU accelerated hardware in the cloud. This code needs to run in an isolated, secure environment, and users should preferably be able to either use Docker images provided by grand-challenge.org, or their own images. A solution is currently being developed that makes use of AWS Batch as a job scheduler. A web application will let the users interact with a fully serverless backend built on top of AWS Lambda,

Amazon DynamoDB, and Amazon API Gateway, to enable them to submit their jobs and manage their results.

Amazon ECR will store container images. A CI/CD pipeline built on top of the AWS CodePipeline service will follow, that will allow users to submit their Dockerfile to have them automatically built and stored in Amazon ECR.

## Amazon SageMaker for Healthcare and Life Sciences

Prepare, build, train, and deploy high-quality machine learning models for healthcare and life sciences use cases

Today, tens of thousands of customers, including leading healthcare and life sciences (HCLS) organizations such as GE Healthcare, Cerner, Bristol Myers Squibb, Roche, and more, use [Amazon SageMaker](#) for machine learning (ML). The HCLS industry faces mounting pressure to deliver more personalized treatments, streamline processes, modernize every aspect of the pharma value chain, and keep patient information private and secure. ML addresses these challenges by automatically identifying anomalies in medical images such as X-rays, building personalized healthcare treatment plans based on historical data and documents, and identifying suspicious healthcare claims so HCLS organizations can offer higher quality, more holistic treatment at lower costs. SageMaker enables patients, providers, payers, and researchers to prepare, build, train, and deploy high quality ML models and offers built in solutions to get started with ML faster.

### Top use cases for Amazon SageMaker



Extract and analyze data from documents

To make decisions faster, healthcare and life sciences organizations need to understand text in medical documents, such as patient forms. With Amazon SageMaker, you can build ML models to automatically extract, process, and analyze data from handwritten and electronic documents so you can process documents faster and more accurately. SageMaker provides built-in ML algorithms that are optimized for text classification, natural language processing (NLP), and optical character recognition (OCR), that you can readily use to train and deploy models, or you can use Amazon SageMaker Autopilot to automatically generate text processing models.



### Fraud detection

To keep patient data secure, it is important for healthcare and life sciences organizations to use fraud detection models to spot suspicious healthcare claims before they impact customers. With Amazon SageMaker, you can build ML models to detect suspicious transactions before they occur and alert your customers in a timely fashion. SageMaker provides built-in ML algorithms, such as Random Cut Forrest and XGBoost, that you can use to train and deploy fraud detection models. In addition, SageMaker provides a set of solutions for fraud detection that can be deployed with just a few clicks.



### Anomaly detection

Healthcare and life sciences organizations continue to look for ways to automatically identify anomalies and accelerate patient diagnosis. With Amazon SageMaker, you can build computer vision models to spot anomalies in medical images and automatically flag for deep analysis and diagnosis. SageMaker provides a broad set of capabilities purpose-built for machine learning including built-in algorithms that are optimized for computer vision, such as image classification, that can improve the diagnosis of patients, reduce the subjectivity in diagnosis, and help save time for pathologists.



### Drug development

Disease understanding and drug development can be tedious and time-consuming, and life sciences companies constantly look for ways to accelerate the drug development process. With Amazon SageMaker, you can easily label training data for a variety of use cases so you can speed the time to train and deploy highly accurate ML models. By automating this tedious work using SageMaker, life sciences companies can accelerate the drug discovery process, introduce medicines to market more rapidly, and deliver life-changing medicines that contribute value to patients and society.

# O que é a visão por computador?

## Reconhecimento automático e descrição de imagens e vídeo

A visão por computador permite que máquinas possam identificar pessoas, lugares e coisas em imagens com precisão humana (ou além) de maneira muito mais rápida e eficiente. Geralmente criada usando modelos de aprendizado profundo, ela automatiza a extração, a análise, a classificação e o entendimento de informações importantes de uma única imagem ou uma sequência de imagens. Os dados da imagem podem assumir vários formatos, como imagens únicas, sequências de vídeo, visualizações por meio de várias câmeras ou dados tridimensionais.

Os aplicativos têm grande abrangência, da identificação de defeitos em linhas de montagem de alta velocidade a robôs autônomos e análise de imagens médicas, bem como a identificação de produtos e pessoas nas redes sociais.

---

## Casos de uso e benefícios da visão por computador

### Segurança pública e segurança interna

A visão por computador com reconhecimento de imagens e faces ajuda a identificar rapidamente entradas ilegais ou suspeitos de crimes, o que resulta em comunidades mais seguras e uma maneira mais eficiente de prevenir crimes.

### Autenticação e interação otimizada entre ser humano e computador

A interação otimizada entre ser humano e computador melhora a satisfação do cliente ao, por exemplo, oferecer produtos baseando-se na análise de sentimento do cliente em lojas de varejo, ou serviços

bancários mais rápidos com autenticação rápida baseando-se na identidade e nas preferências do cliente.

### **Análise e gerenciamento de conteúdo**

Com milhões de imagens adicionadas diariamente a canais de mídia e redes sociais. O uso das tecnologias de visão por computador, como extração de metadados e classificação de imagens, melhora imensamente a eficiência e as oportunidades de geração de receita.

### **Direção autônoma**

Com o uso de tecnologias de visão por computador. Os fabricantes de automóveis podem proporcionar uma navegação automotiva para condução automática melhor e mais segura ao tornar uma realidade a direção autônoma, além de transformá-la em uma opção de transporte confiável.

### **Imagiologia médica**

A análise de imagens médicas com a visão por computador pode melhorar imensamente a precisão e a velocidade de diagnóstico médico de um paciente, o que resulta em resultados mais satisfatórios de tratamento e maior expectativa de vida.

### **Controle do processo de fabricação**

Uma visão por computador bem treinada incorporada à robótica melhora o controle de qualidade e a eficiência operacional em aplicativos de fabricação, o que resulta em produtos mais co

## Visão por computador na AWS

O Amazon Rekognition é um serviço que torna fácil e rápido adicionar classificação de imagens e pesquisa visual baseadas em aprendizado profundo aos seus aplicativos. Com o Rekognition, você pode detectar objetos, cenas e faces em imagens. Você também pode pesquisar e comparar faces, reconhecer celebridades e identificar conteúdo impróprio.

Integrado à AWS, o Amazon Rekognition disponibiliza uma plataforma de reconhecimento de imagens veloz, escalável, confiável e segura para ajudar clientes a obter de modo eficiente informações rápidas e novas oportunidades de geração de receita por meio da biblioteca de imagens deles, de acordo com a escala empresarial de que necessitam.

### AWS HealthImaging Customers

#### Alara Imaging

"Alara Imaging makes it easier than ever to achieve secure, bi-directional communication of medical imaging data between on-premises storage and the cloud. Alara Imaging is proud to work with AWS HealthImaging to support modern, cloud-native medical imaging to improve health systems and patient outcomes."

Nate Mazonson, CEO, Alara Imaging

#### ApolloEI

"At ApolloEI, we are experts in delivering enterprise imaging clinical workflow solutions to our customers. We are in the process of shifting arcc, our multi-disciplinary medical imaging platform, to be cloud-native on AWS. We are thrilled to build on top of AWS HealthImaging and take advantage of its scalability for image import and image viewing."

Mark J. Newburger, President & CEO, ApolloEI

## CoreSlicer

"The CoreSlicer team is passionate about applying technology to quantify body composition from medical images. Our technology uses deep learning to illuminate biomarkers that enable doctors to deliver care that is more proactive, precise, and patient centered. We are excited to be collaborating with AWS on the development of our platform for a global user base. We are impressed by AWS HealthImaging's fast image viewing and tight integration with other AWS services."

Jonathan Afilalo, Principal Scientist & Founder, CoreSlicer

## Dicomatics

"Dicomatics is a leader in seamless and scalable medical imaging data migration. From on prem to the cloud, we excel in handling petabyte-scale and complex migrations. With the power of AWS HealthImaging, our customers now have a specialized cloud service dedicated to storing their valuable data, fueling clinical workloads, and groundbreaking research."

Aviram Biton, Strategic Partnership, Dicomatics

## Flywheel

"Flywheel's medical imaging AI development platform, together with the power of AWS HealthImaging, is helping to revolutionize research, drug development, and care delivery by providing the needed AI + data management tools for standardizing, curating, annotating, and training complex medical imaging datasets. Together we can help the healthcare industry extract greater value, deeper insights, and accelerate disease diagnosis and drug efficacy."

Dan Marcus, Chief Scientific Officer, Flywheel

## NVIDIA

"MONAI, co-founded and accelerated by NVIDIA, is a domain-specific, medical imaging AI framework that speeds the translation of

research breakthroughs and AI applications to clinical impact. With the integration of MONAI and AWS HealthImaging, medical images can be viewed, processed, and segmented in near real time—optimizing physician workflows, enhancing patient experiences, and helping hospitals improve efficiencies."

Prerna Dogra, Global Lead for Healthcare AI Products, NVIDIA

### Philips

"Our vision is to help clinicians and staff manage growing workloads and optimize workflows to speed time to diagnosis and treatment of patients. AWS purpose-built services, like HealthImaging, can help Philips innovate faster and serve our customers and their patients. Our cloud-enabled HealthSuite Imaging PACS intends to use AWS HealthImaging to improve experiences and accessibility for clinicians all over the world."

Shez Partovi, Chief Innovation & Strategy Officer and Chief Business Leader of Enterprise Informatics, Philips

### Radboudumc

"At Radboud University Medical Center, our mission is to be a pioneer in shaping a more person-centered, innovative future of healthcare. We are building a collaborative AI solution with AWS HealthImaging for clinicians and researchers to speed up innovation by putting ML algorithms into the hands of clinicians faster."

Bram van Ginneken, Chair of the Diagnostic Image Analysis Group, Radboudumc

### Radical Imaging

"Radical Imaging is streamlining medical imaging in the cloud through its viewer-as-a-service product FlexView. AWS HealthImaging is a key enabler for us to deliver on our promise of any image, any workflow, anywhere; securely, with maximum performance, at scale."

Rob Lewis, CEO & Founder, Radical Imaging

## Atrium Health

"Atrium Health is a nationally recognized leader in shaping health outcomes through innovative research, education, and compassionate patient care. A leader in experiential medical education and groundbreaking research, Wake Forest University School of Medicine is the academic core of the enterprise, including Wake Forest Innovations, which is advancing new medical technologies and biomedical discoveries. Our mission is to improve health, elevate hope, and advance healing—for all. We are actively collaborating with AWS to explore AWS HealthImaging's capabilities, which could help Atrium Health deliver on this mission on the cloud."

Rasu Shrestha, MD MBA, Executive Vice President, Chief Strategy and Transformation Officer, Atrium Health

## University of Maryland Medical Intelligent Imaging (UM2ii) Center

"UM2ii was formed to unite innovators, thought leaders, and scientists across academics and industry. Our work with AWS will accelerate our mission to push the boundaries of medical imaging AI. We are excited to build the next generation of cloud-based intelligent imaging with AWS HealthLake Imaging and Amazon's experience with scalability, performance, and reliability."

Paul Yi, MD, Director, UM2ii Center

## Visage Imaging

"Visage is a leading global provider of enterprise imaging solutions that enable PACS replacement at local, regional, and national scale. Visage is leading the way with 100% of our new customers over the past 3 years have implemented Visage 7 in the cloud. Visage 7 CloudPACS is ultrafast, providing sub-second access to all patient imaging coupled with the most extensive advanced visualization tools that enable radiologists to read more cases with greater clinical precision. With AWS HealthImaging, Visage 7 customers will have even more flexibility to manage and unleash the value of their enterprise imaging data assets."

Sam Hupert, MD, CEO, Visage Imaging

## VIDA

"At VIDA, our mission is to accelerate research, clinical trials, and adoption of life saving treatments through AI-enabled clinical imaging data workflows. AWS HealthImaging is accelerating our roadmap by allowing us to rapidly implement DICOM imaging services. By speeding development and enabling our R&D team to focus on differentiating functionality, the VIDA Intelligence Portal is now thriving in the market."

Todd Johnson, CTO, VIDA

### Next steps

Start using HealthImaging

Begin with HealthImaging in the AWS Management Console.

[Get started »](#)

Connect with an expert

Reach out to the AWS Support team.

[Learn more »](#)

Explore HealthImaging FAQs

Find answers to commonly asked questions.

[Learn more »](#)

# How Google Cloud and AWS Are Battling for Dominance in Medical Imaging

Recent Posts

- [Celonis Introduces Transformation Hub: Process Mining for Rapid Value Creation](#)

- [On Location at Workday Rising: AICPA VP Ash Noah's Essential Human Skills for CFOs](#)
- [Happy Thanksgiving to All!](#)
- [AI Index: OpenAI's DevDay; Lidl Invests in AI Startup; Carmax's New AI Feature](#)
- [OpenAI Disaster: Sam Altman, Satya Nadella and Microsoft Win Big](#)

The capabilities of the cloud to transform the [healthcare](#) industry are profound. Consequently, healthcare providers and their collective pain points are becoming some of the biggest drivers for cloud innovation.

Take [Oracle](#). Chairman Larry Ellison described the company's [healthcare endeavors](#) as so significant they are transforming the organization's culture. And Oracle isn't the only cloud provider with a serious commitment to healthcare.

[Google Cloud](#) and [AWS](#) have developed dedicated cloud technologies for the healthcare sector. And now, there is a new race on to master medical imaging.

### **Why Is Medical Imaging So Important?**

Medical imaging is one of the most important diagnostic tools in the medical arsenal because it enables healthcare professionals to find and identify diseases quickly and assess their progression. Medical imaging, which encompasses procedures like X-ray, MRI, ultrasound, CT, and endoscopy, is advancing at a staggering rate and plays an increasingly prominent role in diagnostics.

When it comes to the [cloud](#), medical imaging has a solid support base. When you separate the images from the healthcare professional's diagnosis, you're left with data. Google estimates that as much as 90% of [healthcare data](#) is medical imagery.

And when it comes to making data accessible, organized, and coherent, cloud technologies provide the most superior and wide-reaching solutions.

### **What's the Google Cloud Play?**

Google Cloud recently launched the latest element to its image-based artificial intelligence (AI) offerings, the [Medical Imaging Suite](#).

The focus of the technology is to simplify the diagnostic process and reduce the workload on healthcare professionals by using AI to scan medical imagery and make an accurate diagnosis.

If you've been following our coverage, you'll know that AI is becoming increasingly user-friendly, and as a result, companies are onboarding more off-the-shelf AI solutions. The Medical Imaging Suite follows this model and provides doctors with ready-to-go tools for tasks like image labeling and annotation.

There are options for advanced procedures, like bespoke AI modeling and data analysis. However, the technology is fundamentally simple to operate and available as a cloud service where medics can share secure data via Google Cloud's Healthcare app.

### **What About AWS?**

So, what does AWS have to say about all of this? It, too, has just launched a new advance in medical imaging on the cloud. The service, HealthLake Imaging, comes in the form of new capabilities for [Amazon HealthLake](#), a health data cloud platform launched last year.

These new capabilities expand the existing platform to provide medics with a method of transitioning medical imaging workflows to the cloud. The aim is to make medical imaging data more readily available, better structured, and less energy-intensive — thanks to the absence of duplicates.

The [low-latency](#) system enables images to be streamed instantly via multiple devices. Ultimately, AWS is providing a scalable solution that should encourage healthcare providers to switch these processes to the cloud.

### **Wrap Up**

While Google Cloud is focusing on pain points and reducing person hours, AWS appears to be taking a more comprehensive approach. It's looking at the introduction of cloud-based medical image retrieval and analysis as a driver for cloud adoption.

Undoubtedly, we can expect more organizations to pick up the baton and create more use cases for cloud-based medical imaging. As with any critical use case in the Acceleration Economy, there is

space for competition. Success depends on angle, approach, and uniqueness.

# How Medical Image Analysis Will Benefit Patients and Physicians

Automated medical image analysis is set to change the way physicians work and bring benefits to medical organizations and their patients.

Images are the largest source of data in healthcare and, at the same time, one of the most difficult sources to analyze. Clinicians today must rely largely on medical image analysis performed by overworked radiologists and sometimes analyze scans themselves.

This is a situation set to change though, as pioneers in medical technology apply artificial intelligence to image analysis. [Computer vision software](#) based on the latest deep learning algorithms is already enabling automated analysis to provide accurate results that are delivered immeasurably faster than manual process can achieve.

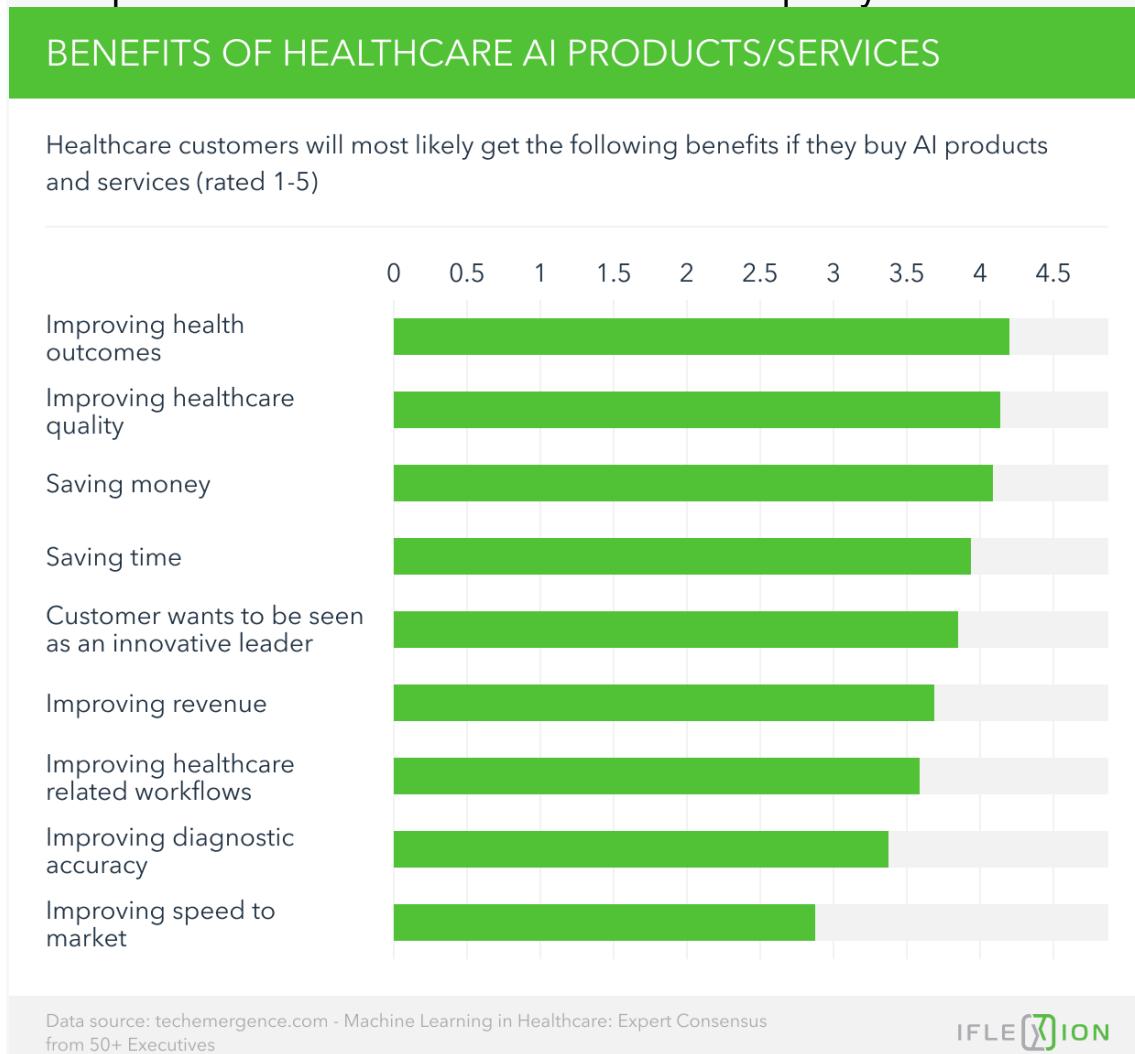
As these automated systems become pervasive in the healthcare industry, they may bring about radical changes in the way radiologists, clinicians, and even patients use imaging technology to monitor treatment and improve outcomes.

Computer vision software is already enabling automated analysis to provide accurate results that are delivered immeasurably faster than manual process can achieve.

## Who Will Benefit from Automated Medical Image Analysis?

In this article, we want to emphasize how advanced medical image analysis will benefit specific stakeholders, so we'll limit the description of general AI benefits to the graph below, which represents the opinions of technology providers in the healthcare industry.

As the graph indicates, executives in this sales niche believe the most compelling AI (including imaging technologies) benefits to be the improvement of outcomes and healthcare quality.

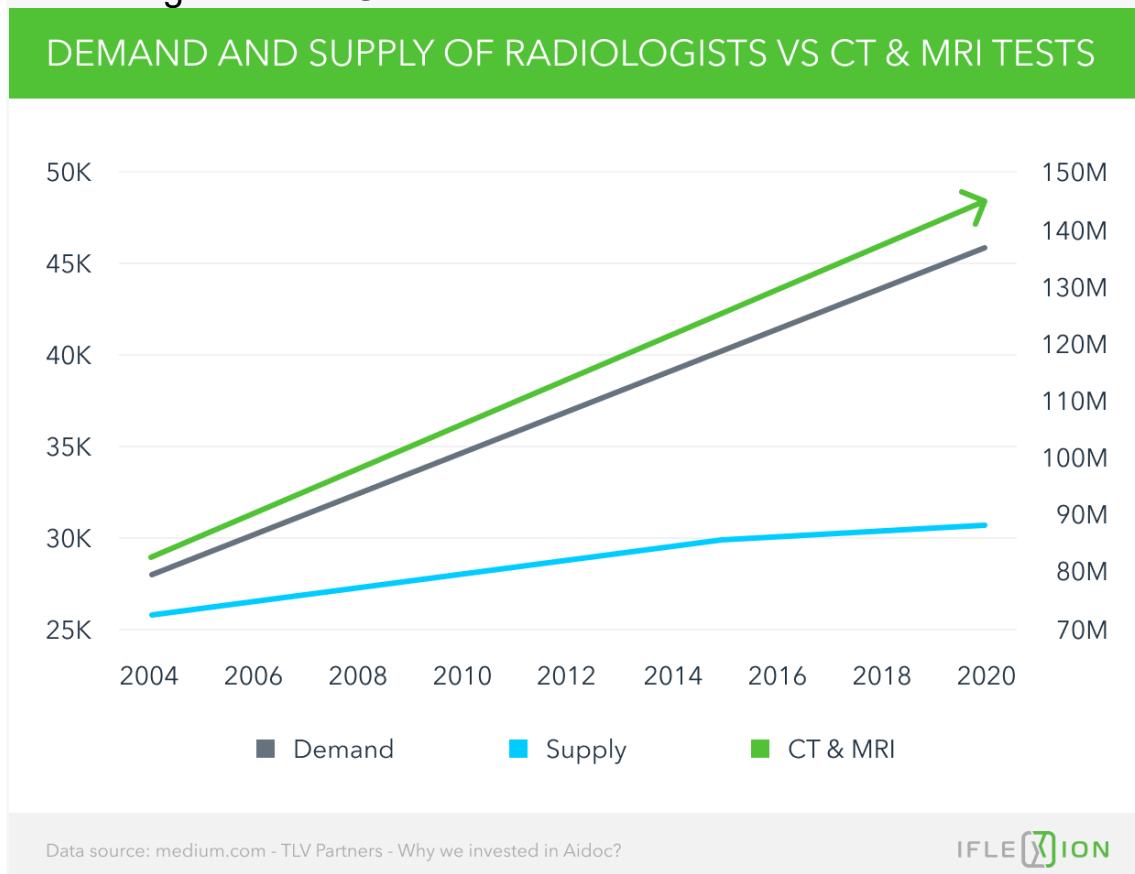


As the examples of [healthcare app development](#) in this article will show, applying machine-learning AI to the analysis of medical X-ray images and scans will bring a number of these benefits to the following three key groups of stakeholders:

- Radiologists
- Non-Radiologist
- Clinicians Patients

## Radiologists

In simple terms, there are currently not enough radiologists to cope with the ever-growing volumes of data captured by X-rays, MRI, PET, CT, and ultrasound. This is clearly highlighted in the graph below, which shows the mismatch between the demand and supply of radiologists in the United States.



*Personnel Today* reports that in the United Kingdom, the National Health Service has seen radiologists' workloads increase by 30% over a five-year period, while the workforce has increased by only 15%, and warns that radiologist services may collapse if the human resource shortage is not alleviated.

Automated image analysis will ease the burden on radiologists everywhere, by eliminating the need for them to scrutinize every image in the search for anomalies. Instead, clinicians will only need

to focus on images that deep learning algorithms flag for their attention.

AI may even present radiologists with suggestions as to the nature of detected abnormalities. In the fight against cancer, for instance, this might require algorithms to highlight the likelihood of a tumor being either benign or malignant. This will help doctors focus on patients who need attention while easing their diagnostic workload and supporting them in making appropriate decisions.

### **Non-Radiologist Clinicians**

AI-driven image analysis software will bring about a change in the roles of radiologists and other clinicians alike. Radiologists will be able to spend less time screening images and concentrate on diagnosis and decision-making. The same technology will provide non-radiologist physicians with digital assistance to interpret medical images, making them less reliant on hospital radiology departments.

For example, even without extensive sonography or radiology training, clinicians are typically able to make some straightforward diagnoses by examining ultrasound images. Intelligence provided by automated image analysis will extend their capabilities, enabling all doctors and even paramedics to interpret images from portable ultrasound scanners.

### **Patients**

The third group to benefit from advanced medical image analysis will be those whom healthcare exists to serve—patients. They will receive timelier and more accurate diagnoses, and will no longer have to wait weeks for results of X-ray studies.

The range of applications for self-monitoring will increase, including wearable self-scanning solutions. In the hospital setting, patients will be subject to fewer invasive procedures and will have less need to endure the introduction of toxic or radioactive tracer drugs into their bodies. Radiation doses from CT scans and X-rays will be reduced, and fewer scans will be necessary to diagnose or monitor each patient's condition.

Applying machine-learning AI to the analysis of medical X-ray images and scans will bring a number of benefits to radiologists, non-radiologist clinicians, and patients.

## How Will Enhanced Image Analysis Deliver These Benefits?

The best way to illustrate what automated medical image analysis can do for patients, radiologists, and other clinicians is to show some examples. The innovations discussed in the following sections of this article comprise findings from recent research, solutions in development, and products undergoing commercialization or already in commercial use.

### Automated Medical Image Analysis in CT Scanning

The use of convolutional neural networks to analyze CT scans has seen much progress and growth in the last couple of years, but has mainly involved 2D slices from a patient's chest, abdomen, or brain. Yet breakthroughs are on the way, as innovators have improved the performance of deep learning solutions that analyze the entire 3D image series from a CT scan.

One company specializing in deep learning technology for the medical field, called *Aidoc*, recently launched the first full-body solution for CT analysis, which will afford radiologists a workflow-integrated application, enabling them to analyze scans of the chest, c-spine, abdomen, and head, without the need to switch between discrete image analysis applications.

Breakthroughs are on the way, as innovators have improved the performance of deep learning solutions that analyze the entire 3D image series from a CT scan.

### Boosting the Speed, Power, and Comfort of MRI

Like CT scanning, Magnetic Resonance Imaging (MRI) is a non-invasive method of examining the internal workings of the body. Unlike CT scanning, MRI presents less risk to patients, because it does not emit radiation in order to capture images. Its main drawback, however, is the long examination time. For instance, a cardiac MRI can take more than an hour to perform.

By applying to this problem image analysis based on machine learning, San Francisco company *Arterys* has developed a solution that not only cuts down the time needed for cardiac MRI examinations but also increases the quantity and quality of data provided. Better still, Arterys' *ViosWorks* application eliminates another MRI issue—the need for patients to hold their breath during certain sequences of the examination.

### VIOSWORKS, ADVANCED APP FOR CARDIAC MRI EXAMS

ViosWorks demonstrates the directional flow of blood in the heart and vessels.

Color depicts velocity of blood flow.

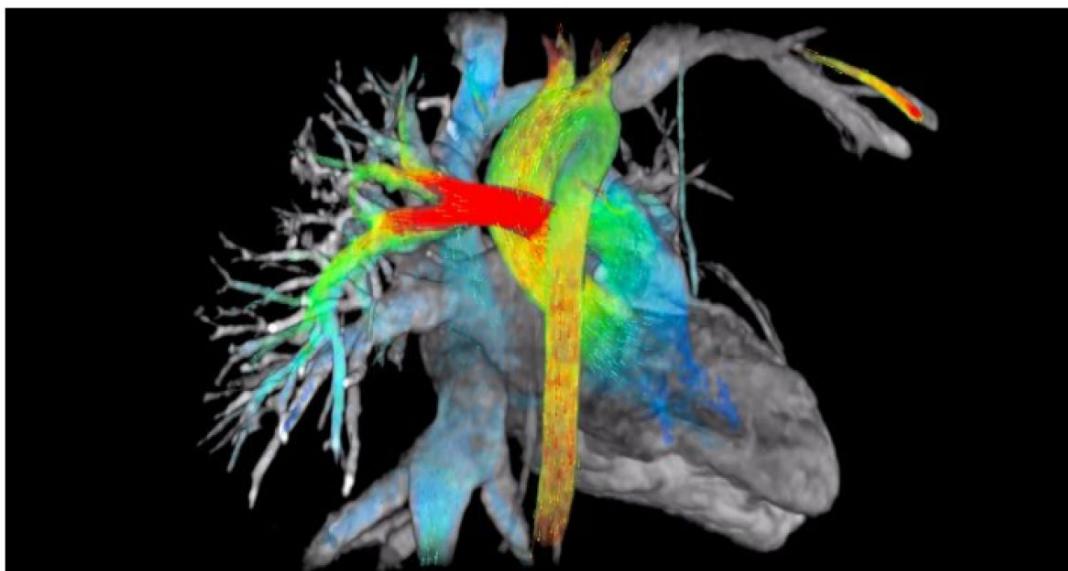


Image source: [itnonline.com](http://itnonline.com) - GE Unveils Software to Greatly Simplify Cardiac MRI Workflow

FILEXION

ViosWorks enhances images from MRI scanners, delivering a 3D view of the heart with the addition of visualized and quantified blood-flow data. According to *Imaging Technology News*, ViosWorks enables the capture of 20 gigabytes of data in a fraction of the time required for conventional MRI technology to acquire just 200 megabytes.

This enables a patient to breathe freely throughout the examination, unlike conventional scans, during which a patient may have to spend periods holding her breath. For instance, during a cardiac MRI assessment, a patient will be asked to remain perfectly still, without breathing, as many as 14 times during the examination.

Build your image recognition solution for healthcare with

## Greater Safety and Accuracy for PET Scans

In addition to diagnosis, medical imaging techniques, such as PET scanning, are becoming increasingly useful in evaluating patients' response to treatment, particularly for cancer. Early and frequent response evaluation is essential, for example, when using chemo and radiation therapy to treat lung cancer.

When physicians can assess patient response in the first week or two of treatment, they can adapt dosages, either by reducing them to alleviate toxicity in non-diseased tissue or by increasing dosage for patients whose tumors are not responding positively.

## The Pitfalls of PET Imaging

PET scanning enables early response evaluation and is also a non-invasive alternative to biopsy, but it requires patients to receive an internal dose of a radioactive drug known as a "tracer." This drug enables the PET scanning equipment to capture images of the organ or area of interest in the patient's body.

The need to use what is essentially a toxic substance is one of the drawbacks of PET scanning. Another is the possibility of smaller lesions—or lesions absorbing only a small quantity of the tracer—being missed by the scan. There is also a risk of photon misidentification, which can lead to losses in PET image intensity and contrast.

## The Addition of Algorithms to PET Scanning Solutions

Research has shown that machine learning can improve the effectiveness of PET medical image analysis. Algorithms can be developed and trained to remove image noise, improve quality, and gather image data in greater quantities and at a faster rate than standard PET equipment can. Consequently, the quantities of radioactive tracer needed to capture reliable images may be reduced, which, of course, is good news for patients who must undergo PET scans.

The reduction of toxicity is not the only benefit for cancer patients. Integration of machine learning into PET scanning and medical

image analysis offers the following advantages over conventional technology:

- Improved image quality relieves the need for follow-up scans, thereby reducing patients' overall exposure to the tracer drug.
- Instant high-quality imaging allows physicians to make decisions much earlier, even during the scanning process, hence speeding up and improving the accuracy of treatment.
- Tumors can be monitored frequently and non-invasively to match chemo and radiotherapy doses to treatment response, thus increasing the prognosis and survivability of lung cancer.

Machine learning algorithms can even be trained to classify tumors in PET images, for example, as either being responsive or non-responsive to treatment. This alleviates the workload for radiologists and increases productivity, so more patients can benefit from prompt decisions and appropriate treatment protocols.

Research has shown that machine learning can improve the effectiveness of PET medical image analysis.

## Making Ultrasound More User-Friendly

While all the aforementioned machine-learning-driven advances in medical image analysis offer great promise, some of the most exciting developments are taking place in the ultrasound-imaging domain.

In a 2017 *Medium* article, radiologist Kevin Seals boldly suggests that the marriage of new semiconductor-powered probes built as smartphone peripherals with image analysis software may soon allow patients to scan themselves and capture ultrasound data for use in their treatment or condition monitoring.

## Ultrasound on a Chip

Kevin Seals' predictions are not merely speculative. One new solution uses a sophisticated probe and machine learning artificial intelligence software—dubbed *ultrasound on a chip*—and has already received FDA approval that Seals describes as “robust.”

## BUTTERFLY iQ PLUGGED INTO A SMARTPHONE



Image source: Butterfly

IFLEXION

Furthermore, the system is expected to cost less than \$2,000, which positions it as a viable replacement for the ubiquitous stethoscope. This is an incredible leap for ultrasound technology, which has up till now involved the use of multiple probes, each with a very limited breadth of application, by sonographers extensively trained to make sense of the images they produce.

Direct patient ultrasound might still be some way off, but direct access and interpretation of ultrasound imaging for all clinicians, not just radiologists, would appear to be just around the corner.

Direct patient ultrasound might still be some way off, but direct access and interpretation of ultrasound imaging for all clinicians, not just radiologists, would appear to be just around the corner.

## Enhancing the Effectiveness of X-rays

The sheer quantity of X-ray images captured daily presents a huge problem for clinicians around the world. For example, an [Imaging Technology News article](#) puts the number of diagnostic X-ray images captured annually by the UK's National Health Service at over 22 million, but with not enough radiologists to analyze such a vast quantity, more than 200,000 patients had to wait a month or

more for their X-ray results, as reported by the *Express* news website.

By making it possible to automate the initial screening of X-rays, image analysis software can help radiologists keep up with their workload. By screening every image using trained algorithms, computers can classify the content of X-rays and raise alerts for those requiring detailed scrutiny by a skilled human clinician.

## Automating X-ray Analysis

One such example of automated screening is a system being used in developing countries to detect signs of tuberculosis visible in chest X-rays. The solution, developed by a subsidiary of Canon, uses machine learning to detect abnormalities with more accuracy than human screening staff, although it hasn't yet proven as accurate as physicians who specialize in TB diagnosis and treatment.

Given the shortages of radiologists in developing countries, though, an automated solution with a better-than-average degree of accuracy will doubtlessly help many patients receive early diagnosis and treatment, and therefore decrease mortality rates.

Elsewhere, artificial neural networks are removing subjectivity from the assessment of skeletal tumor burden on prostate cancer patients. As this form of cancer can spread from the prostate into a patient's bones, physicians use X-rays to identify when this happens and assess how much of the skeletal structure is affected. A new machine-learning solution has been developed that can read and interpret X-rays, and by measuring bone density, *objectively* quantify the extent of tumor growth.

A new machine-learning solution has been developed that can read and interpret X-rays, and by measuring bone density, objectively quantify the extent of tumor growth.

## Bringing it All Together: Multimodal Medical Image Analysis

Few clinicians, especially radiologists, would deny the value of automated assistance in the detection of medical anomalies from CT, MRI, X-ray, ultrasound, or PET images. Solutions for classifying and analyzing images from each specific imaging mode will

undoubtedly help clinicians treat more patients, with greater accuracy, and in a timelier manner than they can manage using manual methods alone.

These types of machine learning solutions are only the beginning though, with artificial intelligence systems such as IBM's Watson already being developed to interpret patients' entire medical history data, including analysis of visual data from multiple modalities.

## Training Doctor Watson

In other words, the time may soon be upon us when a clinician can call up a patient's latest chest X-ray for example, and receive not only a suggested diagnosis of any abnormalities in that X-ray, but also a concise yet detailed study of historic visual and other data from the patient's records.

The study might contain analyses of all prior X-rays or images captured using other methods (such as CT, MRI, ultrasound, and PET), enabling the clinician to make a fast, accurate diagnosis and prepare an appropriate program of treatment.

Again, this is not a speculative opinion, but rather, a reflection of what is already being achieved by companies such as Agfa, using the Watson system, which was trained for medical image analysis following IBM's 2016 acquisition of *Merge Healthcare*.

Solutions for classifying and analyzing images from each specific imaging mode will undoubtedly help clinicians treat more patients, with greater accuracy.

## Medical Image Analysis: Making the Data Work

IBM researchers claim that 90% of medical data is sourced from imaging solutions, but with painstaking manual scrutiny as the primary means of medical image analysis, there's little wonder clinicians find the process akin to drinking water from a fire hose.

Machine learning for image analysis will put data to better use, improving the way physicians allocate their time and supporting them in delivering better outcomes, and in so doing, will deliver important benefits to the stakeholders who matter most—patients,

who depend on medical imaging for their wellness, health, and survival.

Machine learning for image analysis will put data to better use, improving the way physicians allocate their time and supporting them in delivering better outcomes.

# AI Applications: an Overview of 8 Emerging Artificial Intelligence Use Cases

## Introduction

Artificial intelligence (AI) is the all-encompassing term for technologies built and developed to automate tasks previously performed by humans. Back in 1950, Alan Turing published his famous paper about the possibility of thinking machines<sup>1</sup>. However, up until the early 2000s, humanity hadn't made much progress on AI for various reasons. Some of the biggest reasons for that were lack of computer processing power, funding, and actual data necessary for machines to learn about the real world<sup>2</sup>.

However, that's been changing for the past couple of decades, with the rapid adoption of the internet, a trillion-fold increase in processing power since the 1950s<sup>3</sup>, and the explosion of technologies that collect and catalog data<sup>4</sup>.

With this rapid pace of innovation, AI became a **viable business tool**. The AI market is on track to outpace many industries. The business value of AI is poised to reach over 3 billion dollars within the next couple of years<sup>5</sup>, and many companies are trying to cash in on this opportunity.

This report was created to highlight industries that have the potential to experience or are already experiencing technological transformation brought on by AI. We selected the banking, healthcare, and insurance industries for this research to expose a good variety of AI-driven innovations and focus on industries that are ripe for disruption and are already making steps towards AI ubiquity. For example, industries

like manufacturing have been experimenting with AI for quite some time now, and so such an exposé for manufacturing might not be as revealing.

Many market players haven't yet caught up with the pace of change. However, it's evident that market leaders in the selected industries are already reaping the benefits of artificial intelligence, machine learning, natural language processing, image recognition, and other AI technologies. In this report, we'll review some of the specific use cases of artificial intelligence in daily life of various industries.

The business value of AI is poised to reach over 3 billion dollars within the next couple of years, and many companies are trying to cash in on this opportunity.

## Disrupting the Banking Sector with AI

It's difficult to expand the already existing growth of opportunities in banking. The market is saturated with the growing pool of fintech companies planning to provide banking products on different, sometimes better terms than banks do.

Banks carry a heavier regulatory burden, which changes constantly and in some cases stifles innovation<sup>6</sup>. Legacy systems that banks employ are also dragging down their growth, while fintechs have the opportunity to start with an already competitive tech stack.

Nevertheless, many of the banking leaders already apply AI applications to achieve incredible productivity and efficiency gains.

### 1. Anti-Money Laundering and AI

The global footprint of money laundering is staggering, as up to 5% of the global GDP is laundered annually<sup>7</sup>, which amounts to almost 4 trillion dollars<sup>8</sup>. That's why governments around the globe are tightening regulations to combat this trend. EU's anti-money laundering directives or the USA Patriot Act<sup>10</sup> are prime examples of such regulations.

These regulations pressure banks by increasing the compliance burden. But money laundering has other risks, which banks have to deal with.

### Money Laundering Burden and Risks

## Reputational

Involvement in money laundering operations can seriously tarnish a bank's reputation and negatively impact future business opportunities or client preferences.

## Regulatory

Failure to comply with regulations can halt operations and result in fines, asset forfeiture, and other negative effects on the business.

## Operational

Anti-money laundering (AML) operations require significant financial and talent investments.

## Technological

Increased diversity and complexity of banking interactions, carried out through multiple channels, further complicate the necessary practices to combat money laundering.

Artificial intelligence has the power to influence the efficiency of anti-money laundering programs directly. Only 2%<sup>11</sup> of all suspicious transactions result in a crime. From 2012 to 2016, the number of suspicious activity reports rose by 2000%<sup>12</sup>. Banks have to use AI to keep up with the growing number of threats and elevate the relatively low success rate.

One of the most comprehensive approaches to solving this problem is building an intelligent system, which combines AI-powered transactions monitoring and the bank's Know Your Customer (KYC) framework. This creates a comprehensive view of banking activities and provides more context for money laundering detection. Unlike rule-based systems, AI can detect anomalous behavior a lot more effectively because it can identify patterns that lie outside of the usual purview of an AML system.

Banks that use such systems already can see incredible ROI. For example, Florida's QuantaVerse essentially automates 70% of investigation routines<sup>13</sup> and provides complex, AI-generated reports for investigators, allowing the bank to minimize the false positives rate. There is still a human in the loop, but the process is much more streamlined and accurate.

A system combining AI-powered transactions monitoring and the bank's KYC framework can identify user behavior patterns that lie outside of the usual purview of an anti-money laundering system.

## 2. Risk Management with AI

Artificial intelligence is becoming a quite lucrative risk management tool for banks, especially given the abundance of robust financial datasets. The opportunities are endless as practically any banking line of business has use cases, which can be dramatically improved through advanced predictions, generated by AI.

### Risk Management Opportunities for AI in Banking

#### Credit Risk

AI can help banks identify the best credit allocation opportunities using not just the application data, but also the transactions or business history of the prospect. These solutions also include loan servicing tools that save time and minimize human error for the lender.

#### Churn Risk

Banks can use AI to identify clients at-risk of churn, based on their transactions and banking activity data.

#### Collections Management

Collections department can use debtors' personal data and allow AI systems to identify people more likely to repay their debt and even identify channels optimal for engaging them.

#### Mortgage Risks

Banks can use mortgage repayment data, combining it with clients banking activity, to identify mortgages at risk of default and prepayment.

#### Fraud Detection

AI systems can be used to identify fraudulent transactions, using sophisticated anomaly detection algorithms.

#### Investment Risks

Banks can use the loan, investment, or mortgage data to identify risky opportunities or portfolios.

### Model Risk Management

Advanced AI systems are capable of monitoring model performance and identifying models with deteriorating performance.

The examples of these innovations are abundant. JPMorgan uses COIN, a machine learning system that analyzes commercial credit data. The system saves the company hundreds of hours of manual labor<sup>14</sup> and minimizes credit processing errors.

Customer churn prediction is a popular AI use case among financial institutions, especially given the rising competition from other banks and fintech startups. The beauty of AI apps in this niche lies in the fact that they offer intimate insights about the specific churn reasons. This data can be used to drive online service improvements and personalization<sup>15</sup>.

Artificial intelligence is becoming a lucrative risk management tool for banks, especially given the abundance of robust financial datasets.

Wanting to build an intelligent banking app?

## Improving Healthcare Outcomes with AI Apps

Healthcare is a booming industry, which is used to the spotlight attention of global corporations that create artificial intelligence. There are many reasons for this. Healthcare is a public good. Creating AI for healthcare is good PR. Healthcare organizations collect tons of data and are driven by scientific discovery that relies on data. Healthcare is a challenging industry for AI, as the available data is complex by default. That's why even the biggest names in AI have failed here before<sup>16</sup>.

However, companies that successfully deliver artificial intelligence applications for healthcare are in for incredible revenue opportunities, akin to being the first to develop a life-saving vaccine.

Many of the leading healthcare organizations are exploring and investing in AI. The applications are practically endless, as long as there's data to work with.

## AI Opportunities in Healthcare

### Image Processing

Advanced AI systems, based on deep learning algorithms can improve diagnostics by analyzing MRI, CT, and other image data.

### Treatment Optimization

AI can detect irregularities and even predict treatment effectiveness by analyzing electronic healthcare records (EHR) data of patients with similar conditions and treatment regimens.

### Operational Optimization

Hospitals can use AI to improve the forecasting accuracy for the daily/weekly flow of inpatients as well as outpatients and optimize staffing needs accordingly.

### Service Improvements

Caregivers can use AI to predict escalation of care with a high degree of accuracy, which allows them to optimize undertriage/overtriage metrics and improve the overall quality of care.

### Readmission Risk Management

AI can predict patients more likely to be readmitted, which allows hospitals to adjust their treatment, improve care, and reduce avoidable readmission rates.

### Disease Analysis

Artificial intelligence can be used to analyze disease progression, as well as deliver disease propensity insights based on EHR data. This information can aid in treatment, and even in marketing efforts.

## 3. Medical Image Processing and AI

This is one of the biggest niches in healthcare AI, poised to become a \$2 billion industry in the next couple of years<sup>17</sup>. Although medical

imaging is not a new application of AI, we decided to place it into the emerging technologies list because of the incredible growth that it's been experiencing over the past couple of years. Since 2014 over \$1.2 billion dollars<sup>18</sup> have been invested in artificial intelligence in this domain.

However, that's just a footprint of the whole market. The leaders in this domain are already building effective AI systems for image recognition.

- UC San Diego developed an AI system that can diagnose eye diseases with a 95% accuracy, just like an experienced ophthalmologist<sup>19</sup>.
- Samsung's AI technology that detects breast lesions in ultrasound images is said to have increased the diagnostic accuracy by 5%<sup>20</sup>.
- Nvidia made the SDK for its Clara Compute Platform available to the general public. It was already used by a tandem of hospitals in the Boston area to develop an algorithm that recognizes abdominal aortic aneurysms<sup>21</sup>.
- The leading educational institutions create separate research units to explore AI in medical imaging, like the Stanford's Center for Artificial Intelligence in Medicine & Imaging<sup>22</sup>.

These and other developments will push AI in medical imaging to the next level. But for now, there are still many obstacles and issues that **AI software developers** in this domain have to overcome. For example, the interpretability of models that make predictions is an issue since most of these models are based on deep learning algorithms, which are almost impossible to explain. Medical image processing is one of the biggest niches in healthcare AI, poised to become a \$2 billion industry in the next couple of years.

#### 4. Disease Analytics with AI

Being able to predict disease progression and propensity allows healthcare organizations to intervene promptly and make a

difference for any type of disease. Machine learning can effectively predict certain diseases with a >90% accuracy rate<sup>23</sup>.

## Some of the Benefits of AI in Disease Analytics

### Improved Treatment

The ability to start the treatment earlier improves clinical results and treatment effectiveness.

### Optimized Cost

Early disease predictions can dramatically reduce costs associated with the treatment.

### Improved Payer Experience

Payers get better visibility into the future costs of treatment and can save on them thanks to a potential improvement of treatment effectiveness.

### Improved Marketing

Patients who are identified as having propensities towards certain diseases can be identified early and marketed to.

iQuity uses a proprietary machine learning technology to predict autoimmune diseases, identifying patients almost a year in advance of traditional methods.

Scientists at the Francis Crick Institute created an AI system that better predicts the risk of death from heart disease, compared to humans. The AI system used hundreds of health and healthcare variables to make the final predictions, while doctors used about two dozen<sup>24</sup>.

Mount Sinai hospital uses artificial intelligence to predict kidney disease<sup>25</sup>, which can affect a host of decisions and variables in the treatment process, from decreasing the need for dialysis to drug adjustments in the treatment plans.

Unlearn.AI is using unsupervised machine learning to predict Alzheimer's progression. Based on their findings, a demo version of a clinical trial simulator<sup>26</sup>. Early diagnosis of this disease could save over \$7 trillion in medical costs in the long run<sup>27</sup>.

These and many other developments in healthcare AI are the reason why ABI Research estimates the saving brought on by its adoption in the healthcare sector can reach over \$50 billion in 2021 alone<sup>28</sup>.

Machine learning can effectively predict certain diseases with a >90% accuracy rate.

## Managing Insurance Risks with AI Applications

The insurance market for AI is growing at a very rapid pace, as legacy approaches to insurance predictions are being disrupted by various technological advances. The industry has a history of working with data<sup>29</sup>, which is the foundation of any modern AI system. Insurance is also famous for hoarding data about its customers to improve various operations, like underwriting, claims management, and reserving. That's why AI is on track to revolutionize the insurance market with use cases popping up in all parts of the insurance lifecycle.

According to a survey by SCOR, these are the operational areas that will experience the biggest transformation due to artificial intelligence<sup>30</sup>.

Apart from these generalized areas of interest, there are specific insurance use cases that can be greatly augmented by artificial intelligence and machine learning systems.

## Major AI Opportunities in Insurance

### Insurance Lead Scoring

Use AI to identify the most profitable insurance applications that are more likely to convert. This allows you to optimize application review and focus on the most lucrative customers.

### Underwriting Automation

Automate the process of application review by using AI to identify policies eligible for automatic acceptance.

### Claims Acceptance Automation

Offload your claims management team by using AI to identify claims that could be automatically marked for payout.

### Price Optimization

Use AI to find the right price equilibrium, which is competitive, profitable, and which improves the likelihood of a policy conversion.

We'll focus on the areas that could potentially experience the highest impact from artificial intelligence: claims management and underwriting (based on the Insurance Nexus study, cited above).

## 5. Claims Management and AI

Claims management is a resource-heavy process in the insurance lifecycle. It directly influences the profitability, retention, and reputation of the insurer. In the UK alone, the average daily payout on auto insurance claims reaches £33.3 million ( $\approx \$43.4$  million)<sup>31</sup>. Insurers are presented with an opportunity to optimize costs associated with these payouts or maybe even optimize the payouts themselves through better claim insights. AI apps can deliver fascinating results in claims management.

Automated claim classification (with AI) can be 30% more accurate than manual processing and has the potential to increase claims management productivity by 80%<sup>32</sup>. This can be used to identify urgent claims, claims with the highest payout potential, claims with fraud risks, etc. An AI system for such classification can potentially reach an almost 100% accuracy. The biggest bottleneck in the process is human error, which leads to inaccurate data being used for classification<sup>32</sup>.

In healthcare, insurance claims classification with AI can lead to almost perfect case prioritization, improved quality of healthcare outcomes, and lower expenses for the payer<sup>33</sup>.

Fraud detection is another important aspect of claims management, especially given the limited resources that insurance companies are working with. SIUs are a precious resource. You only want to engage them on cases most likely to be fraudulent. Insurance fraud in the US alone costs \$40 billion annually<sup>34</sup>, and getting ahead of such fraudulent claims can be a game changer for insurers. The same AI-powered classification systems described above can be

calibrated to classify claims likely to be fraudulent and allow insurers to dispatch the most appropriate resources to investigate in a timely and effective manner.

AI-powered claim classification can be 30% more accurate than manual processing and has the potential to increase claims management productivity by 80%.

## 6. Automating Underwriting through AI

Underwriting is a manual process that includes a variety of repetitive tasks, which, by default, means it has the potential to be automated with artificial intelligence. The modern insurance customer is not going to wait for application approval but instead will go to a different insurance company. So instead of wasting underwriting resources on rubber-stamping generic applications, AI should be used to identify policies that can be automatically accepted or, on the contrary, require an underwriter's review. And many insurers are already betting on digital AI applications to disrupt their legacy approaches to policy management and pricing.

In healthcare, AI is expected to completely automate the underwriting processes for 60% of applications in the near future<sup>35</sup>. The accuracy of these AI systems got to the point where insurers are issuing policies to traditionally risky and uninsured customer categories, like people with chronic diseases and non-citizens.

These potential productivity gains are why the underwriting AI market is already getting its "unicorns", like Planck Re, which received \$12 million in its round A of funding<sup>36</sup>.

However, there are companies offering much more exotic tools for underwriting. One of the examples is EagleView that uses artificial intelligence to catalog and identify property details, which can be used in daily life to refine the underwriting process and ultimately fine-tune pricing for property insurance. Such image recognition technology could also be used to assess damages after major insurance incidents, like hurricanes and floods.

In healthcare, AI is expected to completely automate the underwriting processes for 60% of applications.

## Cross-industry trends

In this section, we will cover some of the trends that are emerging not only in the markets that we have highlighted in this report but in other industries as well.

### 7. Augmented Analytics

If we take a look back at some of the use cases in this report, it becomes obvious that you need people to generate insights and operationalize them. All of the available data science specialists and AI engineers can't possibly cover the demand for machine learning and AI.

That's why Gartner predicts<sup>37</sup> that augmented analytics (AA) will be one of the biggest trends in the coming years. AA means that data scientists, engineers, and business analysts will be aided by automated systems that can build, deploy, and update machine learning models automatically. This will save thousands of person-hours and take productivity to the next level.

These capabilities have the potential to transform how healthcare, banking, and insurance companies are exploring AI and iterating on their findings. Some of the major products in this niche are offered by Dataiku, H2O Driverless AI, RapidMiner, DataRobot, and AWS SageMaker.

Augmented analytics will be one of the biggest trends in the coming years, and it will enable data scientists, engineers, and business analysts to build, deploy, and update machine learning models automatically.

### 8. Robotic Process Automation and AI

Robotic process automation (RPA) has been a growing trend for quite some time now , even before AI became an enterprise buzzword. The difference is that RPA copies routine human actions, while AI copies human intelligence . Think of RPA as a robot that runs the production and AI as a system that runs the robot. However, the future lies in combining RPA and artificial intelligence to create diverse and highly autonomous systems to tackle a variety

of business problems, from process automation to customer interactions.

That's why companies that deliver these synergic solutions are materializing in many industries. For insurance, it's startups like GuideWire and Shift Technology. Companies like WorkFusion offer AI-powered RPA solutions for the healthcare space. Capgemini singles out customer experience management as the most impactful domain for RPA and AI blend in banking.

The future lies in combining RPA and AI to create diverse and highly autonomous systems to tackle a variety of business problems.

## On a Final Note

AI has become an integral part of modern business processes. While transforming everyday life, there are examples of artificial intelligence revolutionizing the way people address challenges in various areas.

The heavily regulated banking sector can use the power of artificial intelligence to increase the effectiveness of anti-money laundering investigations, thus being more accurate in identifying fraudulent activities and getting enough time to prevent them. AI also broadens the banks' risk management capabilities by allowing them to predict credit risks, customer churn, collection, and investment risks with higher precision.

Owing to great volumes of data processed in healthcare, the industry is to benefit immensely from AI. From treatment and operational optimization to readmission risk management—the scope of healthcare domains that [AI consultants](#) can foster through intelligent technologies is impressive. Medical image analysis is one of the fastest developing technologies and it's able to improve the diagnostics outcomes significantly. At the same time, healthcare providers can use disease analytics to excel in predicting diseases, thus getting the opportunity to foresee them or cut their progression.

When AI comes to the insurance area, it can foster such domains as claim management, underwriting, fraud prevention, customer services, sales, and marketing recommendations. The greatest thing about AI in [insurance software](#) is that it brings automation to various resource-heavy and time-consuming processes, which allows

insurers to reduce human effort while improving the insurance outcomes substantially.

Apart from several industry-specific AI applications, there are at least two increasingly popular AI domains that will influence various spheres. While augmented analytics (AA) is being developed as a new paradigm of automated data preparation and sharing, robotic process automation (RPA) coupled with AI can become a new turning page in the history of autonomous systems that will likely accompany or even replace humans in a variety of business processes.

Artificial intelligence (AI) is the all-encompassing term for technologies built and developed to automate tasks previously performed by humans. Back in 1950, Alan Turing published his famous paper about the possibility of thinking machines<sup>1</sup>. However, up until the early 2000s, humanity hadn't made much progress on AI for various reasons. Some of the biggest reasons for that were lack of computer processing power, funding, and actual data necessary for machines to learn about the real world<sup>2</sup>.

However, that's been changing for the past couple of decades, with the rapid adoption of the internet, a trillion-fold increase in processing power since the 1950s<sup>3</sup>, and the explosion of technologies that collect and catalog data<sup>4</sup>.

With this rapid pace of innovation, AI became **a viable business tool**. The AI market is on track to outpace many industries. The business value of AI is poised to reach over 3 billion dollars within the next couple of years<sup>5</sup>, and many companies are trying to cash in on this opportunity.

This report was created to highlight industries that have the potential to experience or are already experiencing technological transformation brought on by AI. We selected the banking, healthcare, and insurance industries for this research to expose a good variety of AI-driven innovations and focus on industries that are ripe for disruption and are already making steps towards AI ubiquity. For example, industries like **manufacturing have been experimenting with AI** for quite some time now, and so such an exposé for manufacturing might not be as revealing.

Many market players haven't yet caught up with the pace of change. However, it's evident that market leaders in the selected industries are already reaping the benefits of artificial intelligence, machine learning, natural language processing, image recognition, and other AI technologies. In this report, we'll review some of the specific use cases of artificial intelligence in daily life of various industries. The business value of AI is poised to reach over 3 billion dollars within the next couple of years, and many companies are trying to cash in on this opportunity.

## Disrupting the Banking Sector with AI

It's difficult to expand the already existing growth of opportunities in banking. The market is saturated with the growing pool of fintech companies planning to provide banking products on different, sometimes better terms than banks do.

Banks carry a heavier regulatory burden, which changes constantly and in some cases stifles innovation<sup>6</sup>. Legacy systems that banks employ are also dragging down their growth, while fintechs have the opportunity to start with an already competitive tech stack. Nevertheless, many of the banking leaders already apply AI applications to achieve incredible productivity and efficiency gains.

### 1. Anti-Money Laundering and AI

The global footprint of money laundering is staggering, as up to 5% of the global GDP is laundered annually<sup>7</sup>, which amounts to almost 4 trillion dollars<sup>8</sup>. That's why governments around the globe are tightening regulations to combat this trend. EU's anti-money laundering directives or the USA Patriot Act<sup>10</sup> are prime examples of such regulations.

These regulations pressure banks by increasing the compliance burden. But money laundering has other risks, which banks have to deal with.

### Money Laundering Burden and Risks

Reputational

Involvement in money laundering operations can seriously tarnish a bank's reputation and negatively impact future business opportunities or client preferences.

### Regulatory

Failure to comply with regulations can halt operations and result in fines, asset forfeiture, and other negative effects on the business.

### Operational

Anti-money laundering (AML) operations require significant financial and talent investments.

### Technological

Increased diversity and complexity of banking interactions, carried out through multiple channels, further complicate the necessary practices to combat money laundering.

Artificial intelligence has the power to influence the efficiency of anti-money laundering programs directly. Only 2%<sup>11</sup> of all suspicious transactions result in a crime. From 2012 to 2016, the number of suspicious activity reports rose by 2000%<sup>12</sup>. Banks have to use AI to keep up with the growing number of threats and elevate the relatively low success rate.

One of the most comprehensive approaches to solving this problem is building an intelligent system, which combines AI-powered transactions monitoring and the bank's Know Your Customer (KYC) framework. This creates a comprehensive view of banking activities and provides more context for money laundering detection. Unlike rule-based systems, AI can detect anomalous behavior a lot more effectively because it can identify patterns that lie outside of the usual purview of an AML system.

Banks that use such systems already can see incredible ROI. For example, Florida's QuantaVerse essentially automates 70% of investigation routines<sup>13</sup> and provides complex, AI-generated reports for investigators, allowing the bank to minimize the false positives rate. There is still a human in the loop, but the process is much more streamlined and accurate.

A system combining AI-powered transactions monitoring and the bank's KYC framework can identify user behavior patterns that lie outside of the usual purview of an anti-money laundering system.

## 2. Risk Management with AI

Artificial intelligence is becoming a quite lucrative risk management tool for banks, especially given the abundance of robust financial datasets. The opportunities are endless as practically any banking line of business has use cases, which can be dramatically improved through advanced predictions, generated by AI.

### Risk Management Opportunities for AI in Banking

#### Credit Risk

AI can help banks identify the best credit allocation opportunities using not just the application data, but also the transactions or business history of the prospect. These solutions also include loan servicing tools that save time and minimize human error for the lender.

#### Churn Risk

Banks can use AI to identify clients at-risk of churn, based on their transactions and banking activity data.

#### Collections Management

Collections department can use debtors' personal data and allow AI systems to identify people more likely to repay their debt and even identify channels optimal for engaging them.

#### Mortgage Risks

Banks can use mortgage repayment data, combining it with clients banking activity, to identify mortgages at risk of default and prepayment.

#### Fraud Detection

AI systems can be used to identify fraudulent transactions, using sophisticated anomaly detection algorithms.

#### Investment Risks

Banks can use the loan, investment, or mortgage data to identify risky opportunities or portfolios.

#### Model Risk Management

Advanced AI systems are capable of monitoring model performance and identifying models with deteriorating performance.

The examples of these innovations are abundant. JPMorgan uses COIN, a machine learning system that analyzes commercial credit data. The system saves the company hundreds of hours of manual labor<sup>14</sup> and minimizes credit processing errors.

Customer churn prediction is a popular AI use case among financial institutions, especially given the rising competition from other banks and fintech startups. The beauty of AI apps in this niche lies in the fact that they offer intimate insights about the specific churn reasons. This data can be used to drive online service improvements and personalization<sup>15</sup>.

Artificial intelligence is becoming a lucrative risk management tool for banks, especially given the abundance of robust financial datasets.

## Improving Healthcare Outcomes with AI Apps

Healthcare is a booming industry, which is used to the spotlight attention of global corporations that create artificial intelligence. There are many reasons for this. Healthcare is a public good. Creating AI for healthcare is good PR. Healthcare organizations collect tons of data and are driven by scientific discovery that relies on data. Healthcare is a challenging industry for AI, as the available data is complex by default. That's why even the biggest names in AI have failed here before<sup>16</sup>.

However, companies that successfully deliver artificial intelligence applications for healthcare are in for incredible revenue opportunities, akin to being the first to develop a life-saving vaccine.

Many of the leading healthcare organizations are exploring and investing in AI. The applications are practically endless, as long as there's data to work with.

## AI Opportunities in Healthcare

## **Image Processing**

Advanced AI systems, based on deep learning algorithms can improve diagnostics by analyzing MRI, CT, and other image data.

## **Treatment Optimization**

AI can detect irregularities and even predict treatment effectiveness by analyzing electronic healthcare records (EHR) data of patients with similar conditions and treatment regimens.

## **Operational Optimization**

Hospitals can use AI to improve the forecasting accuracy for the daily/weekly flow of inpatients as well as outpatients and optimize staffing needs accordingly.

## **Service Improvements**

Caregivers can use AI to predict escalation of care with a high degree of accuracy, which allows them to optimize undertriage/overtriage metrics and improve the overall quality of care.

## **Readmission Risk Management**

AI can predict patients more likely to be readmitted, which allows hospitals to adjust their treatment, improve care, and reduce avoidable readmission rates.

## **Disease Analysis**

Artificial intelligence can be used to analyze disease progression, as well as deliver disease propensity insights based on EHR data. This information can aid in treatment, and even in marketing efforts.

### **3. Medical Image Processing and AI**

This is one of the biggest niches in healthcare AI, poised to become a \$2 billion industry in the next couple of years<sup>17</sup>. Although medical imaging is not a new application of AI, we decided to place it into the emerging technologies list because of the incredible growth that it's been experiencing over the past couple of years. Since 2014 over \$1.2 billion dollars<sup>18</sup> have been invested in artificial intelligence in this domain.

However, that's just a footprint of the whole market. The leaders in this domain are already building effective AI systems for image recognition.

- UC San Diego developed an AI system that can diagnose eye diseases with a 95% accuracy, just like an experienced ophthalmologist<sup>19</sup>.
- Samsung's AI technology that detects breast lesions in ultrasound images is said to have increased the diagnostic accuracy by 5%<sup>20</sup>.
- Nvidia made the SDK for its Clara Compute Platform available to the general public. It was already used by a tandem of hospitals in the Boston area to develop an algorithm that recognizes abdominal aortic aneurysms<sup>21</sup>.
- The leading educational institutions create separate research units to explore AI in medical imaging, like the Stanford's Center for Artificial Intelligence in Medicine & Imaging<sup>22</sup>.

These and other developments will push AI in medical imaging to the next level. But for now, there are still many obstacles and issues that **AI software developers** in this domain have to overcome. For example, the interpretability of models that make predictions is an issue since most of these models are based on deep learning algorithms, which are almost impossible to explain.

Medical image processing is one of the biggest niches in healthcare AI, poised to become a \$2 billion industry in the next couple of years.

#### 4. Disease Analytics with AI

Being able to predict disease progression and propensity allows healthcare organizations to intervene promptly and make a difference for any type of disease. Machine learning can effectively predict certain diseases with a >90% accuracy rate<sup>23</sup>.

Some of the Benefits of AI in Disease Analytics

Improved Treatment

The ability to start the treatment earlier improves clinical results and treatment effectiveness.

### Optimized Cost

Early disease predictions can dramatically reduce costs associated with the treatment.

### Improved Payer Experience

Payers get better visibility into the future costs of treatment and can save on them thanks to a potential improvement of treatment effectiveness.

### Improved Marketing

Patients who are identified as having propensities towards certain diseases can be identified early and marketed to.

iQuity uses a proprietary machine learning technology to predict autoimmune diseases, identifying patients almost a year in advance of traditional methods.

Scientists at the Francis Crick Institute created an AI system that better predicts the risk of death from heart disease, compared to humans. The AI system used hundreds of health and healthcare variables to make the final predictions, while doctors used about two dozen<sup>24</sup>.

Mount Sinai hospital uses artificial intelligence to predict kidney disease<sup>25</sup>, which can affect a host of decisions and variables in the treatment process, from decreasing the need for dialysis to drug adjustments in the treatment plans.

Unlearn.AI is using unsupervised machine learning to predict Alzheimer's progression. Based on their findings, a demo version of a clinical trial simulator<sup>26</sup>. Early diagnosis of this disease could save over \$7 trillion in medical costs in the long run<sup>27</sup>.

These and many other developments in healthcare AI are the reason why ABI Research estimates the saving brought on by its adoption in the healthcare sector can reach over \$50 billion in 2021 alone<sup>28</sup>.

Machine learning can effectively predict certain diseases with a >90% accuracy rate.

## Managing Insurance Risks with AI Applications

The insurance market for AI is growing at a very rapid pace, as legacy approaches to insurance predictions are being disrupted by various technological advances. The industry has a history of working with data<sup>29</sup>, which is the foundation of any modern AI system. Insurance is also famous for hoarding data about its customers to improve various operations, like underwriting, claims management, and reserving. That's why AI is on track to revolutionize the insurance market with use cases popping up in all parts of the insurance lifecycle.

According to a survey by SCOR, these are the operational areas that will experience the biggest transformation due to artificial intelligence<sup>30</sup>.

Apart from these generalized areas of interest, there are specific insurance use cases that can be greatly augmented by artificial intelligence and machine learning systems.

## Major AI Opportunities in Insurance

### Insurance Lead Scoring

Use AI to identify the most profitable insurance applications that are more likely to convert. This allows you to optimize application review and focus on the most lucrative customers.

### Underwriting Automation

Automate the process of application review by using AI to identify policies eligible for automatic acceptance.

### Claims Acceptance Automation

Offload your claims management team by using AI to identify claims that could be automatically marked for payout.

### Price Optimization

Use AI to find the right price equilibrium, which is competitive, profitable, and which improves the likelihood of a policy conversion.

We'll focus on the areas that could potentially experience the highest impact from artificial intelligence: claims management and underwriting (based on the Insurance Nexus study, cited above).

## 5. Claims Management and AI

Claims management is a resource-heavy process in the insurance lifecycle. It directly influences the profitability, retention, and reputation of the insurer. In the UK alone, the average daily payout on auto insurance claims reaches £33.3 million ( $\approx \$43.4$  million)<sup>31</sup>. Insurers are presented with an opportunity to optimize costs associated with these payouts or maybe even optimize the payouts themselves through better claim insights. AI apps can deliver fascinating results in claims management.

Automated claim classification (with AI) can be 30% more accurate than manual processing and has the potential to increase claims management productivity by 80%<sup>32</sup>. This can be used to identify urgent claims, claims with the highest payout potential, claims with fraud risks, etc. An AI system for such classification can potentially reach an almost 100% accuracy. The biggest bottleneck in the process is human error, which leads to inaccurate data being used for classification<sup>32</sup>.

In healthcare, insurance claims classification with AI can lead to almost perfect case prioritization, improved quality of healthcare outcomes, and lower expenses for the payer<sup>33</sup>.

Fraud detection is another important aspect of claims management, especially given the limited resources that insurance companies are working with. SIUs are a precious resource. You only want to engage them on cases most likely to be fraudulent. Insurance fraud in the US alone costs \$40 billion annually<sup>34</sup>, and getting ahead of such fraudulent claims can be a game changer for insurers. The same AI-powered classification systems described above can be calibrated to classify claims likely to be fraudulent and allow insurers to dispatch the most appropriate resources to investigate in a timely and effective manner.

AI-powered claim classification can be 30% more accurate than manual processing and has the potential to increase claims management productivity by 80%.

## 6. Automating Underwriting through AI

Underwriting is a manual process that includes a variety of repetitive tasks, which, by default, means it has the potential to be automated with artificial intelligence. The modern insurance customer is not going to wait for application approval but instead will go to a different insurance company. So instead of wasting underwriting resources on rubber-stamping generic applications, AI should be used to identify policies that can be automatically accepted or, on the contrary, require an underwriter's review. And many insurers are already betting on digital AI applications to disrupt their legacy approaches to policy management and pricing.

In healthcare, AI is expected to completely automate the underwriting processes for 60% of applications in the near future<sup>35</sup>. The accuracy of these AI systems got to the point where insurers are issuing policies to traditionally risky and uninsured customer categories, like people with chronic diseases and non-citizens.

These potential productivity gains are why the underwriting AI market is already getting its "unicorns", like Planck Re, which received \$12 million in its round A of funding<sup>36</sup>.

However, there are companies offering much more exotic tools for underwriting. One of the examples is EagleView that uses artificial intelligence to catalog and identify property details, which can be used in daily life to refine the underwriting process and ultimately fine-tune pricing for property insurance. Such image recognition technology could also be used to assess damages after major insurance incidents, like hurricanes and floods.

In healthcare, AI is expected to completely automate the underwriting processes for 60% of applications.

## Cross-industry trends

In this section, we will cover some of the trends that are emerging not only in the markets that we have highlighted in this report but in other industries as well.

## 7. Augmented Analytics

If we take a look back at some of the use cases in this report, it becomes obvious that you need people to generate insights and operationalize them. All of the available data science specialists and AI engineers can't possibly cover the demand for machine learning and AI.

That's why Gartner predicts<sup>37</sup> that augmented analytics (AA) will be one of the biggest trends in the coming years. AA means that data scientists, engineers, and business analysts will be aided by automated systems that can build, deploy, and update machine learning models automatically. This will save thousands of person-hours and take productivity to the next level.

These capabilities have the potential to transform how healthcare, banking, and insurance companies are exploring AI and iterating on their findings. Some of the major products in this niche are offered by Dataiku, H2O Driverless AI, RapidMiner, DataRobot, and AWS SageMaker.

Augmented analytics will be one of the biggest trends in the coming years, and it will enable data scientists, engineers, and business analysts to build, deploy, and update machine learning models automatically.

## 8. Robotic Process Automation and AI

Robotic process automation (RPA) has been a growing trend for quite some time now , even before AI became an enterprise buzzword. The difference is that RPA copies routine human actions, while AI copies human intelligence . Think of RPA as a robot that runs the production and AI as a system that runs the robot. However, the future lies in combining RPA and artificial intelligence to create diverse and highly autonomous systems to tackle a variety of business problems, from process automation to customer interactions.

That's why companies that deliver these synergic solutions are materializing in many industries. For insurance, it's startups like GuideWire and Shift Technology. Companies like WorkFusion offer

AI-powered RPA solutions for the healthcare space. Capgemini singles out customer experience management as the most impactful domain for RPA and AI blend in banking.

The future lies in combining RPA and AI to create diverse and highly autonomous systems to tackle a variety of business problems.

## On a Final Note

AI has become an integral part of modern business processes. While transforming everyday life, there are examples of artificial intelligence revolutionizing the way people address challenges in various areas.

The heavily regulated banking sector can use the power of artificial intelligence to increase the effectiveness of anti-money laundering investigations, thus being more accurate in identifying fraudulent activities and getting enough time to prevent them. AI also broadens the banks' risk management capabilities by allowing them to predict credit risks, customer churn, collection, and investment risks with higher precision.

Owing to great volumes of data processed in healthcare, the industry is to benefit immensely from AI. From treatment and operational optimization to readmission risk management—the scope of healthcare domains that [AI consultants](#) can foster through intelligent technologies is impressive. Medical image analysis is one of the fastest developing technologies and it's able to improve the diagnostics outcomes significantly. At the same time, healthcare providers can use disease analytics to excel in predicting diseases, thus getting the opportunity to foresee them or cut their progression.

When AI comes to the insurance area, it can foster such domains as claim management, underwriting, fraud prevention, customer services, sales, and marketing recommendations. The greatest thing about AI in [insurance software](#) is that it brings automation to various resource-heavy and time-consuming processes, which allows insurers to reduce human effort while improving the insurance outcomes substantially.

Apart from several industry-specific AI applications, there are at least two increasingly popular AI domains that will influence various spheres. While augmented analytics (AA) is being developed as a

new paradigm of automated data preparation and sharing, robotic process automation (RPA) coupled with AI can become a new turning page in the history of autonomous systems that will likely accompany or even replace humans in a variety of business processes.

# Accelerate medical research with Amazon OpenSearch Service

DECEMBER 19, 2022 PRAMOD HALAPETI

In the era of large volumes of dynamic data, researchers need a platform that will allow them to ingest data, search in near real-time, and visualize data by using dashboards. Utilizing the Amazon OpenSearch Service to store data, conduct near real-time searches, and use the OpenSearch Service dashboard to display data is one option to expedite the process.

## Introduction

In the field of medical research, time is of the essence. The faster researchers can identify potential new treatments for diseases, the better. However, working with the IT team on basic duties like data intake and creating a dashboard for data insights not only adds to the IT team's workload but also slows down medical research. The back and forth communication can take up a significant amount of time.

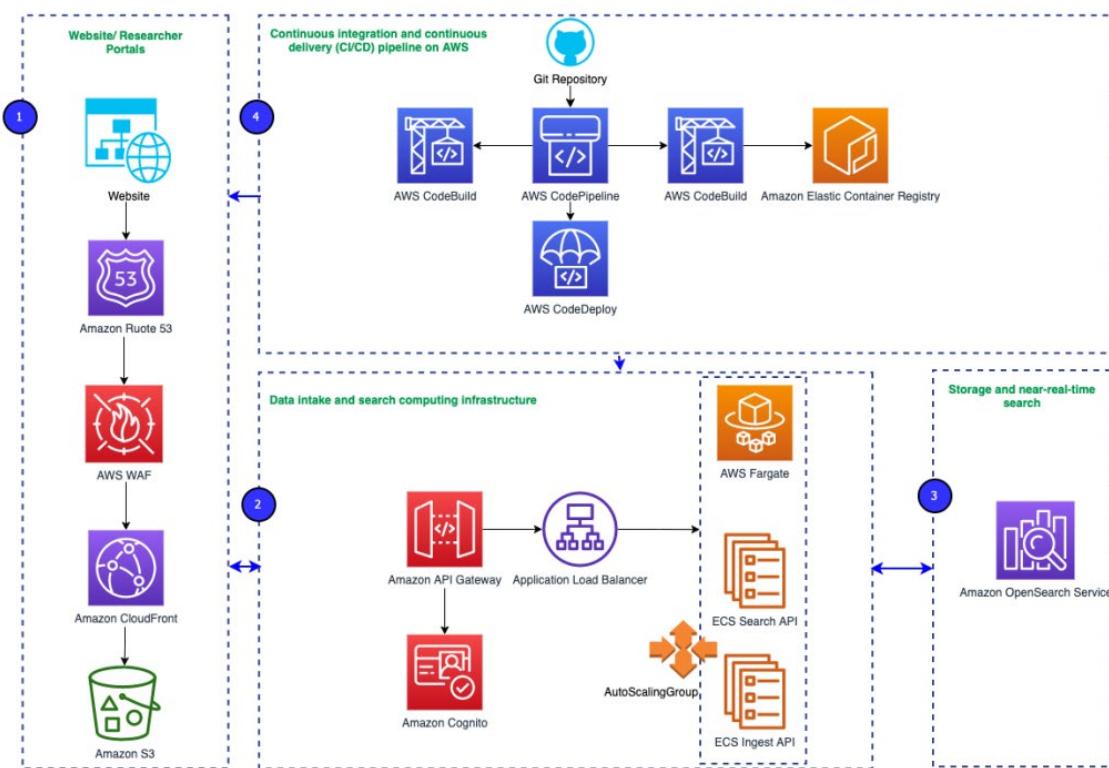
In recent years, medical research has made great strides in developing new treatments and cures for a variety of diseases. However, the process of conducting research is often slow and painstaking, as it can take weeks or even months to collect and

analyze data. Fortunately, there are ways to speed up the process by leveraging Amazon Web Services (AWS).

Medical research can be accelerated by using Amazon OpenSearch Service (OpenSearch Service) with integrated dashboards. This service provides researchers the ability to upload data on-demand, search for information with near real-time results, and create dashboards with in-depth data analysis to gain insights.

By analyzing large datasets, researchers can identify patterns and trends that can be used to formulate new hypotheses. This approach can help accelerate the research process by reducing the amount of time spent on manual data collection and analysis.

## The Architecture



**Figure 1 – High-level architecture of the data ingestion and analytics solution**

Researchers can quickly search through vast amounts of medical data using the OpenSearch service to find the information they

need. Researchers can use the OpenSearch Service dashboard to create visualizations and other analyses of medical data that help gain insights and make discoveries.

The design requires the development of a portal for researchers to use in order to import massive amounts of data into OpenSearch Service whenever they need to. The researcher's portal reduces the amount of time for coordination between the IT team and the resources needed to share large files with the IT team for data ingestion.

We divided the architecture into sections based on component functionality for clarity.

**Section 1:** The element of a solution that researchers engage with is called a website or researcher portal. Researchers can safely log into the website, ingest data into OpenSearch Service, and conduct searches in near real-time. Section 1's use of AWS services:

- Amazon Route 53 (Route 53) provides highly available and scalable Domain Name System (DNS), domain name registration, and health-checking web services. Route 53 connects researchers' web requests to other components of the solutions running on AWS.
- AWS WAF is utilized to provide protection for the solution against common web exploits and bots that have the potential to compromise security, reduce the solution's availability, or consume an excessive number of resources.
- Amazon CloudFront provides researchers the benefit of a faster distribution of both static and dynamic web content. This includes image files as well as .html, .css, and .js files. Amazon CloudFront is responsible for delivering the contents of the researcher's portal to researchers. Amazon CloudFront reduces the amount of time it takes for researchers to download large datasets by utilizing the AWS backbone network.
- Amazon Simple Storage Service (Amazon S3) is a service that is utilized to store application content, such as media files and static assets. This helps reduce the amount of traffic that is

sent to the application web server. This service is reliable and highly available.

**Section 2:** Ingest API and Search API computing infrastructure controls how researchers engage with the underlying data. This can involve things like authenticating users, managing sessions, granting access to data stored in OpenSearch Service clusters, and granting programmatic access to ingest data into an OpenSearch Service cluster. Section 2's use of AWS services:

- Amazon API Gateway (API Gateway) is an AWS service for creating, publishing, maintaining, monitoring, and securing HTTP API's at scale. API Gateway secures and scales the researcher's portal's consumption of Ingest and Search APIs (container-based APIs running on Amazon Elastic Container Service).
- Amazon Cognito provides the researcher's portal with authentication, authorization, and user management. Researchers have the option of logging in directly with a username and password or by using a third-party service such as Facebook, Amazon, Google, or Apple.
- The combination of an Application Load Balancer (ALB) and AWS Auto Scaling enhances application responsiveness, availability, and user experience by distributing traffic across multiple targets, and scaling up or down based on the traffic pattern.
- The solution uses AWS Fargate (Fargate) with Amazon Elastic Container Service (Amazon ECS) to run containers without managing servers. The Search API and Ingest API should be configured to operate as containers. By removing the operational burden of scaling, patching, securing, and

managing servers, Fargate helps the infrastructure team save time. Fargate also reduces server costs by scaling compute to match resource needs, thereby eliminating over-provisioning.

**Section 3:** OpenSearch Service enables researchers to ingest, secure, search, aggregate, view, and analyze data.

The [OpenSearch Service Project](#) continues to provide a secure, high-quality search and analytics suite with a rich roadmap of new and innovative functionality. OpenSearch Service offers different instance sizes to meet computing needs, storage tiers to reduce analytics costs, and features to increase productivity when compared to self-managed solutions.

**Section 4:** Continuous Integration/Continuous Deployment (CI/CD) is a software development practice in which code changes are automatically built, tested, and deployed to production, making the release process more efficient and reliable. Section 4's use of AWS services:

- [AWS CodePipeline](#) (CodePipeline): When code changes, CodePipeline automates the build, test, and deployment of the researcher's portal, Search API, and Ingest API according to the workflow.
- [Amazon Elastic Container Registry](#) (Amazon ECR): The images for the Search API and Ingest API are hosted on Amazon ECR. The [straightforward integration](#) of Amazon ECR and Amazon ECS allows teams to focus on building the applications, not the environment.
- [AWS CodeBuild](#) (CodeBuild) compiles source code, runs tests, and produces packages that are ready to deploy.
- [AWS CodeDeploy](#) (CodeDeploy) facilitates releasing new features, avoiding deployment downtime, updating the researcher's portal, and Ingest API and Search API changes.

Integration with a GitHub repository enables tracking of changes and automatic deployment, testing, and release of modifications to the researcher's portal, Search API, and Ingest API. To host source code, another option is AWS CodeCommit (CodeCommit). CodeCommit is a secure, highly scalable, fully managed source control service that hosts private GitHub repositories.

## Built with Data Security in Mind

When working with sensitive medical information, it is standard practice to encrypt data both in transit and at rest. Encrypt data at rest using customer managed keys for least-privileged access controls and AWS Key Management Service (AWS KMS). AWS KMS lets you create, manage, and control cryptographic keys across your applications and AWS services.

The solution uses Amazon Cognito for user management and authentication to secure the HTTP API in API Gateway. User accounts are stored in Amazon Cognito. The site administrator has control over who can perform OpenSearch Service searches against which indexes and who can ingest data.

It is recommended to launch OpenSearch Service domains into an Amazon Virtual Private Cloud (Amazon VPC). Placing an OpenSearch Service domain within a Amazon VPC enables secure communication between OpenSearch Service and other services within the Amazon VPC without the need for an internet gateway, NAT device, or VPN connection. All traffic remains securely within the AWS Cloud. Application load balancer is internal and can only be connected by API Gateway using a VPC link. Services in Amazon ECS are deployed in a private subnet and configured to be accessed using specific ports from application load balancers.

## Conclusion

Data insights can play a critical role in accelerating medical research. By using data to generate hypotheses, conducting near real-time experiments, researchers can save time and resources while still being able to produce accurate results. These approaches can help speed up the process of developing new treatments and cures for a variety of diseases.

Amazon OpenSearch Service, combined with supporting AWS services, can help researchers accelerate their work by making it straightforward to ingest large amounts of data on-demand and query it to find the information they need. With OpenSearch Service dashboards, researchers can quickly visualize their data to find trends and relationships that would otherwise be difficult to see.

For more information on AWS services in healthcare, life sciences, and genomics, please visit <https://aws.amazon.com/health>. To know what AWS can do for you contact an AWS Representative.

## Further Reading

- Serverless option in Amazon OpenSearch Service
- Developing an HTTP API in API Gateway
- Accessing your private Amazon OpenSearch Service Domain

# AWS Adds Medical Imaging, Analytics Capabilities to HealthLake

Nov. 16, 2022

Cloud vendor estimates that HealthLake Imaging could help health systems reduce the total cost of medical imaging storage by up to 40 percent

Last year, Amazon Web Services (AWS) launched Amazon HealthLake, a service to store, transform, and query health data in the cloud. Now it has announced the launch of new capabilities in HealthLake focused on medical imaging and analytics.

In a [blog post](#), Tehsin Syed, general manager of health AI, and Taha Kass-Hout, M.D., vice president, machine learning and chief medical officer, describe how AWS is working with partners on the launch of HealthLake Imaging to accelerate adoption of cloud-native solutions to help transition enterprise imaging workflows to the cloud and accelerate the pace of innovation.

Intelerad and Arterys are among the launch partners using HealthLake Imaging to achieve higher scalability and viewing performance for their next-generation PACS systems and AI platform, respectively, the AWS execs say. A Boston-based company called Radical Imaging is providing customers with zero-footprint, cloud-capable medical imaging applications using open-source projects, such as OHIF or Cornerstone.js, built on HealthLake Imaging APIs. Nvidia has collaborated with AWS to develop a MONAI connector for HealthLake Imaging. (MONAI is an open-source medical AI framework to develop and deploy models into AI applications, at scale.)

Their blog post explains some of the issues they are working to address. They note that the average imaging study size has doubled over the past decade to 150 megabytes as more advanced imaging procedures are being performed due to improvements in resolution and the increasing use of volumetric imaging. “Health systems store multiple copies of the same imaging data in clinical and research systems, which leads to increased costs and complexity. It can be difficult to structure this data, which often takes data scientists and researchers weeks or months to derive important insights with advanced analytics and machine learning.”

To address these challenges, AWS is previewing Amazon HealthLake Imaging, which it describes as “a new HIPAA-eligible capability that makes it easy to store, access, and analyze medical images at petabyte scale. This new capability is designed for fast, sub-second medical image retrieval in your clinical workflows that you can access securely from anywhere (e.g., web, desktop, phone) and with high availability.”

AWS adds that users will be able to drive their existing medical viewers and analysis applications from a single encrypted copy of the same data in the cloud with normalized metadata and advanced compression. As a result, they estimate that HealthLake Imaging could help them reduce the total cost of medical imaging storage by up to 40 percent.

In a press release, Radical Imaging explained its role. It plans to use HealthLake Imaging with its Open Health Imaging Foundation (OHIF)-based medical imaging viewer, FlexView, to display volume rendering, which creates a three-dimensional representation of data, and segmentation information. HealthLake Imaging uses state-of-the-art image streaming for fast, sub-second, medical image retrieval in clinical workflows by maintaining low latency and high availability anywhere (web, desktop, phone).

"We are excited about Amazon HealthLake Imaging because it enables fast, scalable, secure access to medical images stored in AWS, offering our customers a path to move medical imaging to the cloud with confidence," said Rob Lewis, CEO of Radical Imaging, in a statement. "It helps eliminate barriers to scaling due to performance concerns arising out of DICOM's legacy protocols and the real-time interaction style of medical imaging applications."

The AWS team also included a few quotes from vendor partners in their blog post. "In our continuous path of innovation, our collaboration with AWS, including leveraging Amazon HealthLake Imaging, allows us to innovate more quickly and reduce complexity while offering unparalleled scale and performance for our users," said AJ Watson, chief product officer at Intelerad Medical Systems.

"With Amazon HealthLake Imaging, Arterys was able to achieve noticeable improvements in performance and responsiveness of our applications, and with a rich feature set of future-looking enhancements, offers benefits and value that will enhance solutions looking to drive future-looking value out of imaging data," said Richard Moss, director of product management at Arterys.

## **Amazon HealthLake Analytics**

Syed and Kass-Hout also wrote that AWS is announcing Amazon HealthLake Analytics, which they say makes it easy to query and derive insights from multi-modal health data at scale, at the individual or population levels, "with the ability to share data securely

across the enterprise and enable advanced analytics and machine learning in just a few clicks. This removes the need for you to execute complex data exports and data transformations.”

They add that HealthLake Analytics automatically normalizes raw health data from multiple disparate sources (medical records, health insurance claims, EHRs, medical devices) into an analytics and interoperability-ready format in a matter of minutes.

## KLAS Report Examines Health IT Vendors' Perceptions of Cloud Platforms

Dec. 19, 2022

Health system CIOs need to understand cloud strategies of their software vendors, says Mike Smith, vice president of business development at KLAS

Half of the go-forward products of health IT vendors recently interviewed by KLAS Research are either cloud-native or have been migrated to the cloud. Mike Smith, vice president of business development at KLAS, spoke with *Healthcare Innovation* about how those vendors' perceptions and relationships with Amazon Web Services, Microsoft Azure and Google Cloud Platform are evolving.

Smith first explained why the research firm chose to interview the software vendors about public cloud companies.

When health system CIOs make a decision about which software vendor to use, it is becoming increasingly important to them which public cloud providers those vendors are aligning themselves with, he said. Some of these software vendors were either born in the cloud or are actively migrating to the cloud. “We've actually seen decisions made that have been somewhat focused on what the underlying technologies are,” he said. “We've seen a lot of movement to the cloud on the ERP front, for example. Many people trying to decide which of the vendors they want to go with are probably going to be interested in understanding where they are on their journey to the cloud. We thought it would be helpful for us to

amplify the voices of vendors in regards to how well these cloud providers are performing, in part because they may be the biggest customers that these cloud providers have in healthcare. If we can find out what the software vendors' experience has been, we think it'll actually help the health systems get better visibility into what's happening on the cloud front and how well these cloud providers are performing."

KLAS interviewed 44 health IT software vendors for the December 2022 report, which broke vendors down by segment. In terms of making the most progress on cloud migration, telehealth providers were most advanced, followed by population health, analytics vendors, payer vendors, imaging and core clinical EHRs, where none have all cloud-native products.

"In some of these categories, like telehealth, data analytics and population health, some of those newer vendors were born in the cloud," Smith said, so they did have a little bit of an upper hand. The ones that have legacy solutions have got ground to cover, he said. "In some cases, they are well down the path and have already made what Smith would call a full migration to the cloud. Now they are in the process of trying to get clients moved over to their go-forward solutions. "We certainly see some areas like imaging that are still lacking. It is going to take some more time, and part of the reason is that they have so many legacy solutions to move over."

Any new applications the acute care EMR vendors are building are going to be cloud-based, Smith noted. "I talked to one vendor that has around 20 different products. Most of their products are actually cloud-based solutions, except for their core legacy solution. But that legacy solution represents a high percentage of their revenue. They've moved it to the cloud, but it's more of a 'lift and shift' than really being a cloud-native solution, so they've got work ahead of them to really modernize that application and make it more efficient. Some of those are just going to take a long time."

In terms of how these vendors perceive the three public cloud vendors, Smith said that Microsoft Azure is gaining momentum with software vendors who say they appreciate its integration capabilities and the healthcare industry expertise of its team. AWS is seen as the market leader, and is considered by 95 percent of the vendors interviewed. Google Cloud Platform comes in third in most ratings, but the respondents said it does offer competitive pricing.

Interestingly, about one-third of the vendors said they use multiple cloud providers.

As far as improvements they would like to see, Smith said the health IT vendors said they would like all three public cloud providers to offer more help with cost management tools and they would like the cloud providers to take on more security risk and help them with ransomware issues. They would also like to see more interoperability between cloud providers, he said.

While this is the first KLAS report that looks at how the health IT vendors perceive the cloud platforms, Smith said KLAS will continue to assess health system and vendor use of the cloud. "This has been a long time coming," he said. "We have been hearing about the cloud for 12 years or so. The health system executives are saying they now prefer cloud-based solutions if they can find them. It helps them shrink their data center footprint." There have been announcements about health systems moving their instance of Epic to the cloud, so it will be interesting to hear about their experience after those transitions are made, he said.

## Adobe Launches Experience Cloud for Healthcare

Aug. 14, 2021

Adobe's new offering is an extension of the existing Experience Cloud, using capabilities to meet the needs for hospitals, pharmacies, and insurance companies

According to an [article by Natalie Gagliordi from ZDNet](#), Adobe recently launched its their Experience Cloud for healthcare, the latest vertical of its Experience Platform that is intended to provide personalized customer experiences.

Gagliordi said that "Adobe said the new offering extends existing Experience Cloud capabilities to meet healthcare use cases for hospitals, pharmacies, and insurance companies."

Further, "Adobe said the offering is HIPAA-ready, meaning that it comes with Experience Cloud applications that will be able to comply with HIPAA requirements in early 2022, such as Adobe Real-time Customer Data Platform (CDP) and Journey Optimizer.

Current HIPAA-ready Adobe applications include Marketo Engage, Experience Manager as a Managed Service, Connect as a Managed Service, Adobe Sign, and Adobe Workfront.”

Thomas Swanson, head of industry strategy and marketing for Adobe's Healthcare & Life Sciences unit was quoted in the article saying that "Healthcare brands looking to become trusted partners for their patients and members need to provide contextually relevant experiences across multiple channels while safeguarding consumers' personal data. Adobe is expanding Adobe Experience Cloud's customer experience management capabilities to healthcare with Adobe Experience Cloud for Healthcare. The comprehensive offering is HIPAA-ready and built on Adobe Experience Cloud applications, empowering healthcare companies to improve quality of care, reduce costs, and accelerate the transformation of digital care."

Gagliordi reported key capabilities of the offering include “the ability to leverage Adobe CDP for personalized health recommendations using unified patient data. The platform also offers data governance based on healthcare industry standards, and integrations with a range of software partners, including Accenture, Deloitte, and Microsoft.”

## Mount Sinai Taking Advantage of Azure ‘Large Instances’

Aug. 11, 2023

New York-based health system is migrating many of its workloads to Azure and now has the largest production instance of Epic running on Azure in the world

Mount Sinai Health System in New York is among the first health systems taking advantage of Microsoft Azure Large Instances, a solution designed to achieve the scale needed to run the large Epic electronic health record database — up to 50 million database accesses per second.

Microsoft said Azure Large Instances leverages dedicated resources, which allows Mount Sinai and other Epic clients to scale beyond the previous limits of shared public cloud infrastructure solutions.

On its website, Microsoft explains Azure Large Instances this way: “Some workloads in the enterprise consist of technologies that just aren't designed to run in a typical virtualized cloud setting. They require special architecture, certified hardware, or extraordinarily large servers. Although those technologies have the most sophisticated data protection and business continuity features, they aren't built for the virtualized cloud. They're more sensitive to latencies and noisy neighbors and require more control over change management and maintenance activity. Azure Large Instances is built, certified, and tested for a select set of such applications.”

Working with Accenture, Mount Sinai is migrating many of its workloads to Azure and now has the largest production instance of Epic running on Azure in the world.

“We are very excited about this move as it further enables digital transformation, accelerates artificial intelligence and innovation, provides scalability and flexibility, and reduces upfront infrastructure costs, ultimately leading to improved care and discovery as well as streamlined operations,” said Kristin Myers, executive vice president, chief digital and information officer, and dean for digital and information technology at Mount Sinai, in a statement.

Microsoft notes that health system customers have a growing desire to consolidate and exit on-premises data centers and build for further innovation. The company says its long-standing collaboration with Epic includes enabling the migration of Epic EHR environments to Azure through ongoing joint testing and engineering.

“Through our collaboration with Epic, we are delivering innovation for customers on Azure that will help healthcare organizations reduce the complexity of infrastructure management and control costs with a secure, scalable and agile public cloud solution,” said Tom McGuinness, corporate vice president, global healthcare & life sciences at Microsoft, in a statement.

**Mayo Clinic IT Exec Says Earlier Data Investments Eased Cloud Migration**  
May 12, 2023

James Buntrock, vice chair of information technology, says Mayo Clinic has been on a cloud journey for the last three years, but it has been investing in data warehousing since 2005

During a May 9 webinar hosted by Executives for Health Innovation, James Buntrock, Mayo Clinic's vice chair of information technology, described his organization's cloud journey and relationship with Google Cloud.

Buntrock leads Mayo Clinic's enterprise technology services, which covers enterprise platforms around data, API integration, identity management, as well as digital platforms and digital experience.

Through its websites and consumer applications, Mayo has been on a cloud journey for the last three years. But Mayo Clinic has actually invested in data warehousing since around 2005, he said, and has made incremental improvements to its data platform on premise. "At the peak of that, we were managing between two and three petabytes of data. With the cloud work that we've been doing with Google Cloud, we're up to 30 petabyte of data sets, including multimodal data, which is predominantly driven through imaging and digital pathology," he said, but also new types of data sets that historically they haven't been able to manage at scale, Buntrock said, "so it's giving us an opportunity that we just didn't have before to drive some of these things like enhanced product innovation and improved diagnosis and treatment."

With this foundation in place, Mayo Clinic is seeing more innovation as well as new types of digital tools, he said. "We recently refactored our patient applications, both for mobile and web portal. That's for the first time now running on Google Cloud. That's giving us a base to do more rapid innovation or changes," Buntrock said. Another key area involves artificial intelligence. "Mayo is an academic medical center. We have a number of our "ologies" investing in data science to look for AI methods that could improve things around administrative burden to better prognostics or diagnostics," he said.

As far as managing the cloud relationships, Buntrock said they have to keep a close eye on costs. There's a new term "cloud smart," he said. It requires a different set of disciplines to manage costs. "There is a concept called FinOPs because the volume of the different charges that cloud collects is so high that you have to have new management techniques to manage costs and understand capacity optimization," Buntrock said. "That is one that we're definitely paying attention to and I think that will continue to be a point that we'll be emphasizing in the next two years."

Buntrock also touched on human capital requirements when moving to the cloud. “When we started our Google journey, we had like six people that had any kind of Google experience or cloud experience,” he said, “so that definitely takes time and investment in your workforce, a combination of upskilling and training but also recruiting, and I think that is not an overnight process. So that is a cloud technology constraint. You also are looking for people who not only know cloud technologies, but also know about clinical data and the content as well. As long as I have been doing enterprise data warehousing, understanding data to do ETL, to do mapping, to do semantic normalization is always a challenge. Getting people with the right skills to be able to analyze and make those changes is part of that human capital limitation.”

You have to recognize that this is a big investment, he said. “Don’t underestimate the size of that foundational investment,” Buntrock said, but the return is not just in a year or two; the return is over a decade or longer. “We formalized our first larger data investments in the early 2000s. I mentioned that 2005 was the start of our enterprise data warehousing, but we’ve incrementally added in and it allowed us to jump into the cloud faster, because we had done a lot of data organization, a lot of data investment prior to that starting point.”

## New Amazon HealthLake capabilities enable next-generation imaging solutions and precision health analytics

by Tehsin Syed and Dr. Taha A. Kass-Hout | on 15 NOV 2022 |

in [Amazon HealthLake](#), [Amazon Machine Learning](#), [Artificial Intelligence](#), [Healthcare](#) | [Permalink](#) | [Comments](#) | [Share](#)

At AWS, we have been investing in healthcare since Day 1 with customers including Moderna, Rush University Medical Center, and the NHS who have built breakthrough innovations in the cloud. From developing public health analytics hubs, to improving health equity and patient outcomes, to developing a COVID-19 vaccine in just 65 days, our customers are utilizing machine learning (ML) and the cloud to address some of healthcare’s biggest challenges and drive change toward more predictive and personalized care.

Last year, we launched [Amazon HealthLake](#), a purpose-built service to store, transform, and query health data in the cloud, allowing you to benefit from a complete view of individual or patient population health data at scale.

Today, we're excited to announce the launch of two new capabilities in HealthLake that deliver innovations for medical imaging and analytics.

## **Amazon HealthLake Imaging**

Healthcare professionals face a myriad of challenges as the scale and complexity of medical imaging data continues to increase including the following:

- The volume of medical imaging data has continued to accelerate over the past decade with over 5.5 billion imaging procedures done across the globe each year by a shrinking number of radiologists
- The average imaging study size has doubled over the past decade to 150 MB as more advanced imaging procedures are being performed due to improvements in resolution and the increasing use of volumetric imaging
- Health systems store multiple copies of the same imaging data in clinical and research systems, which leads to increased costs and complexity
- It can be difficult to structure this data, which often takes data scientists and researchers weeks or months to derive important insights with advanced analytics and ML

These compounding factors are slowing down decision-making, which can affect care delivery. To address these challenges, we are excited to announce the preview of Amazon HealthLake Imaging, a new HIPAA-eligible capability that makes it easy to store, access, and analyze medical images at petabyte scale. This new capability is designed for fast, sub-second medical image retrieval in your clinical workflows that you can access securely from anywhere (e.g., web, desktop, phone) and with high availability. Additionally, you can drive your existing medical viewers and analysis applications from a single encrypted copy of the same data in the cloud with normalized metadata and advanced compression. As a result, it is estimated that HealthLake Imaging helps you reduce the total cost of medical imaging storage by up to 40%.

We are proud to be working with partners on the launch of HealthLake Imaging to accelerate adoption of cloud-native solutions to help transition enterprise imaging workflows to the cloud and accelerate your pace of innovation.

Intelerad and Arterys are among the launch partners utilizing HealthLake Imaging to achieve higher scalability and viewing performance for their next-generation PACS systems and AI platform, respectively. Radical Imaging is providing customers with zero-footprint, cloud-capable medical imaging applications using open-source projects, such as OHIF or Cornerstone.js, built on HealthLake Imaging APIs. And NVIDIA has collaborated with AWS to develop a MONAI connector for HealthLake Imaging. MONAI is an open-source medical AI framework to develop and deploy models into AI applications, at scale.

“Intelerad has always focused on solving complex problems in healthcare, while enabling our customers to grow and provide exceptional patient care to more patients around the globe. In our continuous path of innovation, our collaboration with AWS, including leveraging Amazon HealthLake Imaging, allows us to innovate more quickly and reduce complexity while offering unparalleled scale and performance for our users.”

— AJ Watson, Chief Product Officer at Intelerad Medical Systems

“With Amazon HealthLake Imaging, Arterys was able to achieve noticeable improvements in performance and responsiveness of our applications, and with a rich feature set of future-looking enhancements, offers benefits and value that will enhance solutions looking to drive future-looking value out of imaging data.”

— Richard Moss, Director of Product Management at Arterys

Radboudumc and the University of Maryland Medical Intelligent Imaging Center (UM2ii) are among the customers utilizing HealthLake Imaging to improve the availability of medical images and utilize image streaming.

“At Radboud University Medical Center, our mission is to be a pioneer in shaping a more person-centered, innovative future of healthcare. We are building a collaborative AI solution with Amazon HealthLake Imaging for clinicians and researchers to speed up

innovation by putting ML algorithms into the hands of clinicians faster.”

— Bram van Ginneken, Chair, Diagnostic Image Analysis Group at Radboudumc

“UM2ii was formed to unite innovators, thought leaders, and scientists across academics and industry. Our work with AWS will accelerate our mission to push the boundaries of medical imaging AI. We are excited to build the next generation of cloud-based intelligent imaging with Amazon HealthLake Imaging and AWS’s experience with scalability, performance, and reliability.”

— Paul Yi, Director at UM2ii

## Amazon HealthLake Analytics

The second capability we’re excited to announce is [Amazon HealthLake Analytics](#). Harnessing multi-modal data, which is highly contextual and complex, is key to making meaningful progress in providing patients highly personalized and precisely targeted diagnostics and treatments.

HealthLake Analytics makes it easy to query and derive insights from multi-modal health data at scale, at the individual or population levels, with the ability to share data securely across the enterprise and enable advanced analytics and ML in just a few clicks. This removes the need for you to execute complex data exports and data transformations.

HealthLake Analytics automatically normalizes raw health data from multiple disparate sources (e.g. medical records, health insurance claims, EHRs, medical devices) into an analytics and interoperability-ready format in a matter of minutes. Integration with other AWS services makes it easy to query the data with SQL using [Amazon Athena](#), as well as share and analyze data to enable advanced analytics and ML. You can create powerful dashboards with [Amazon QuickSight](#) for care gap analyses and disease management of an entire patient population. Or you can build and train many ML models quickly and efficiently in [Amazon SageMaker](#) for AI-driven predictions, such as risk of hospital readmission or overall effectiveness of a line of treatment. HealthLake Analytics reduces what would take months of

engineering effort and allows you to do what you do best—deliver care for patients.

## Conclusion

At AWS, our goal is to support you to deliver convenient, personalized, and high-value care – helping you to reinvent how you collaborate, make data-driven clinical and operational decisions, enable precision medicine, accelerate therapy development, and decrease the cost of care.

With these new capabilities in Amazon HealthLake, we along with our partners can help enable next-generation imaging workflows in the cloud and derive insights from multi-modal health data, while complying with HIPAA, GDPR, and other regulations.

To learn more and get started, refer to [Amazon HealthLake Analytics](#) and [Amazon HealthLake Imaging](#).

# The AI Training Data Platform for Medical Imaging AI Teams

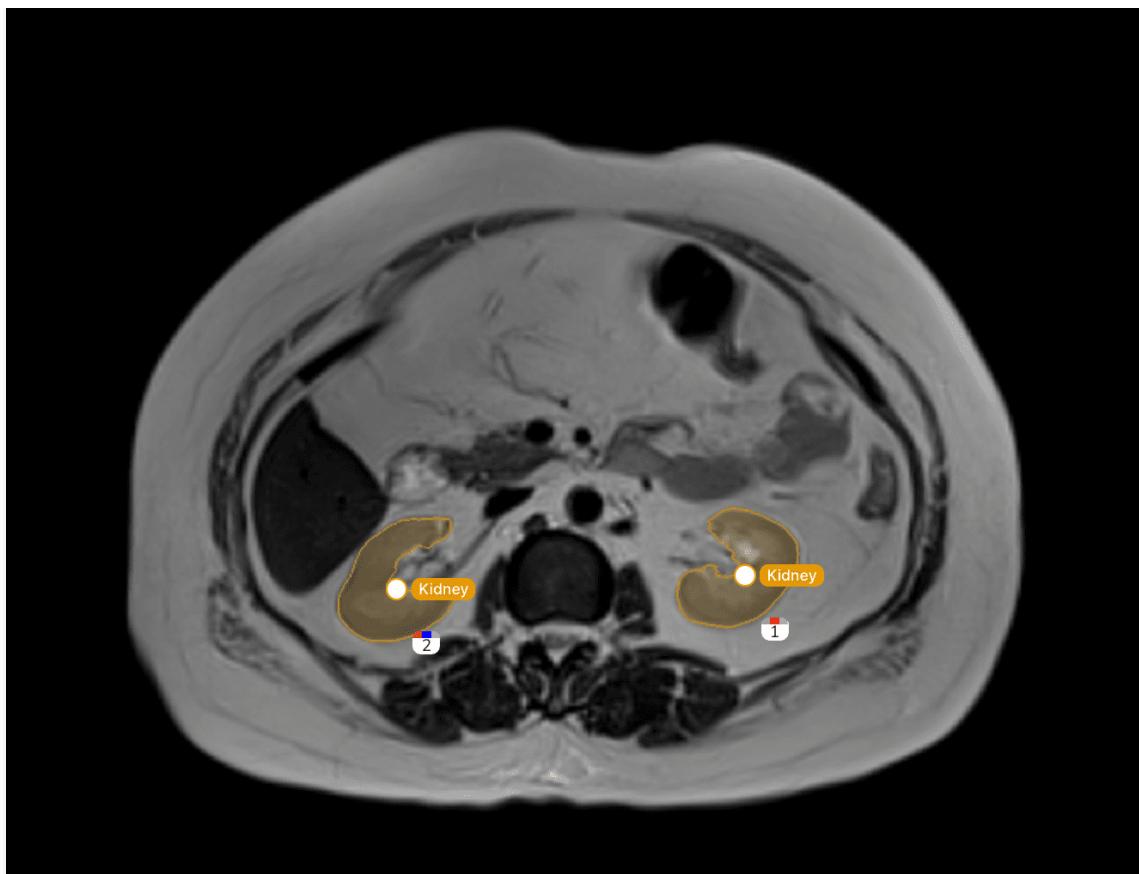
Experience a new level of data accuracy. Automate your video and image labeling with unprecedented speed and efficiency. Train better models. All this on a seamlessly unified platform.

[Read case study ->](#)

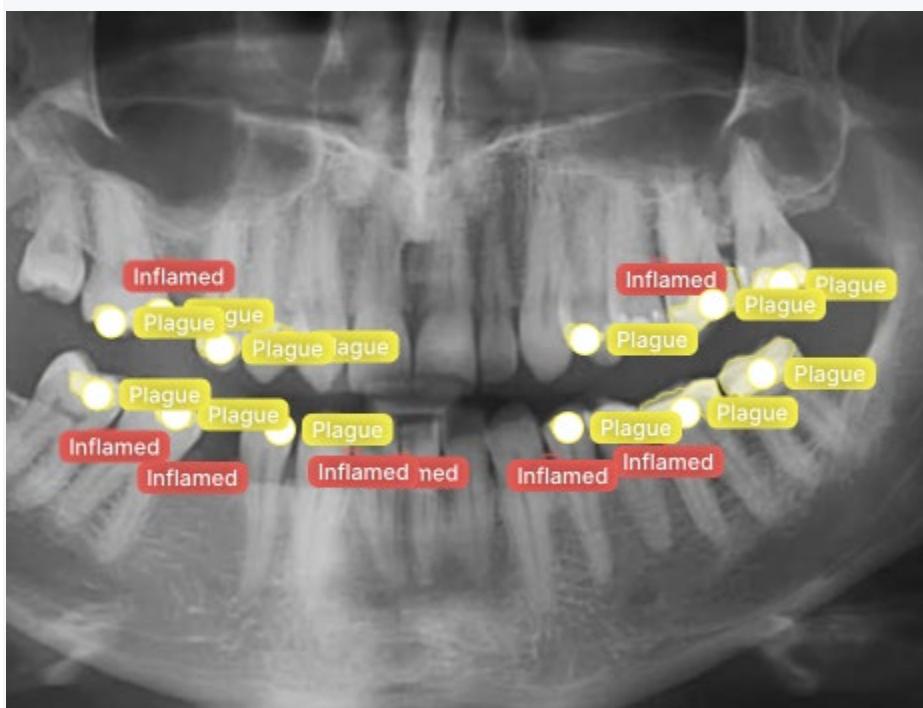
USE CASES

## Explore Medical Use Cases

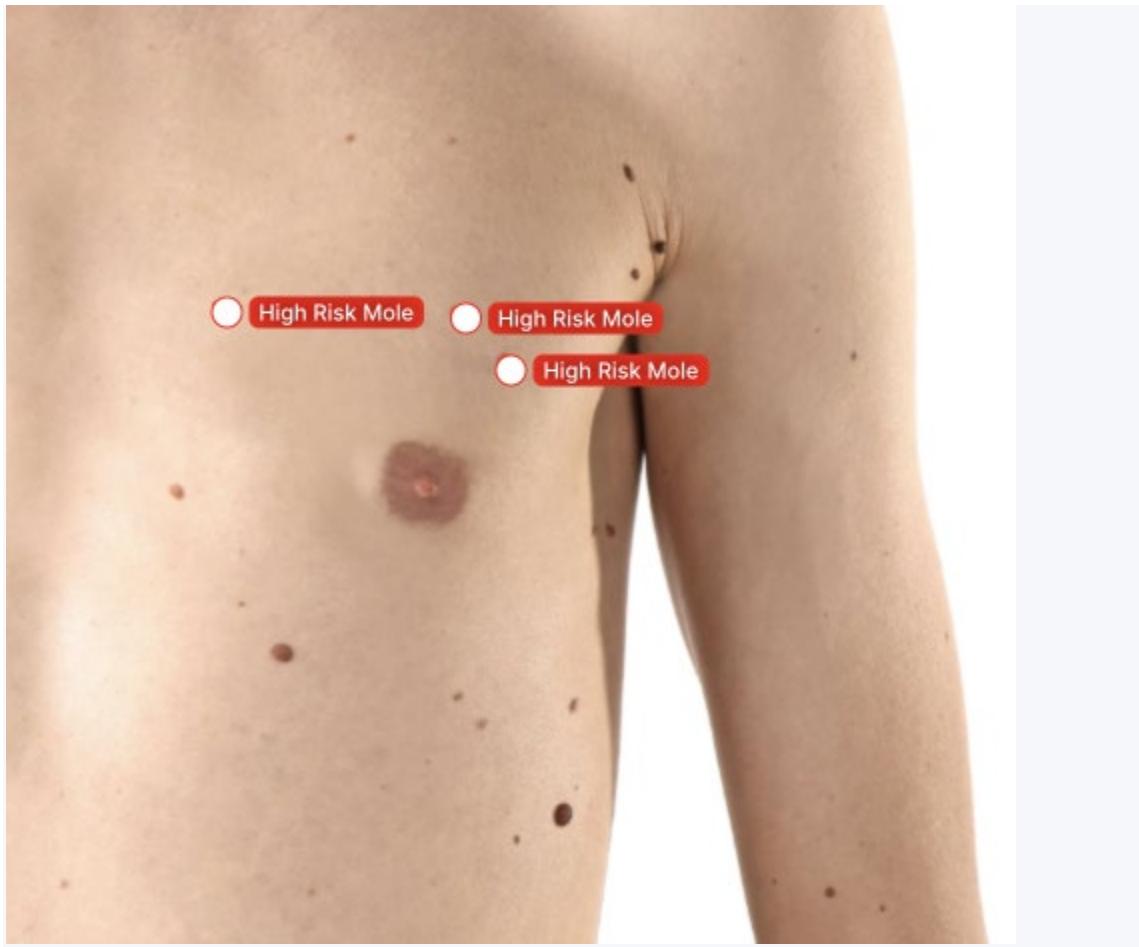
Talk to our team about solving your training data challenges in 100+ use cases.



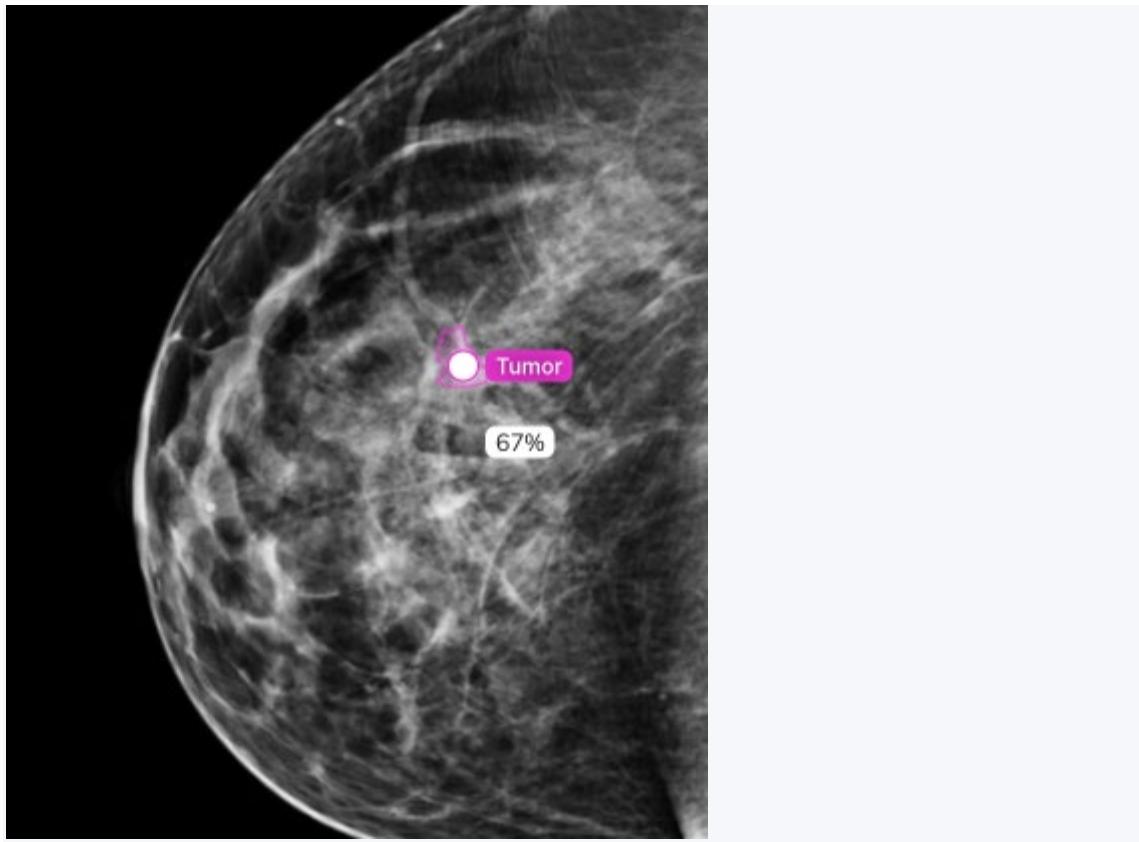
CT and MRI Scan Analysis



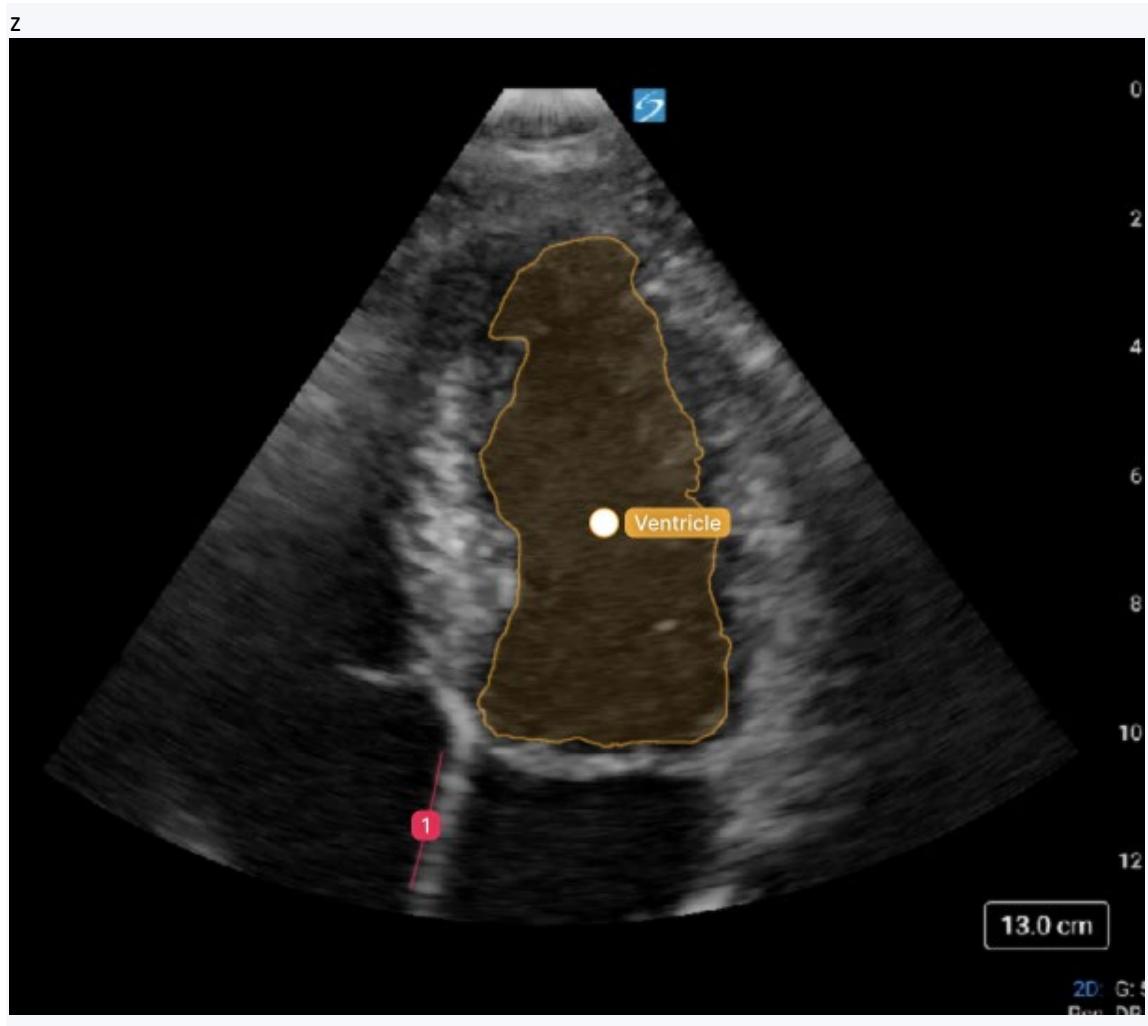
Dental Image Analysis



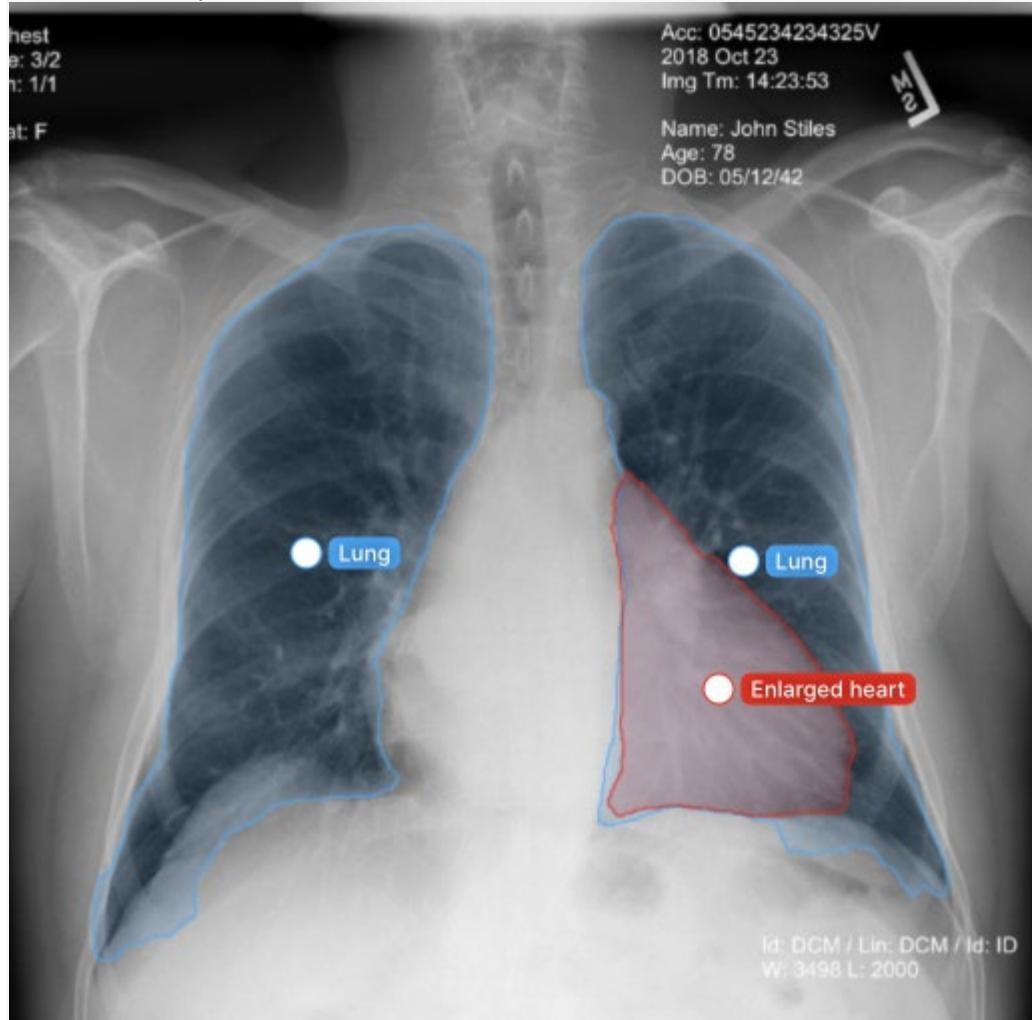
Dermatology Image Analysis



Mammography Image Analysis



## Ultrasound Analysis



## X-Ray Image Analysis

**BRING YOUR DATA**

What is your use case?

[Let's talk!](#)



**ML PIPELINE**

Build robust ML pipelines, deploy  
reliable AI faster

Automate labeling and gain unparalleled control of your annotation workflow. Scale your ground truth creation 10x today.

#### SECURITY

## The most secure platform for training data

You can rest assured that your data remains protected and private,

## Custom workflows for any ML project

Workflows is V7's way of helping you structure your ML pipeline—from uploading your data, labelling and reviewing it, to training accurate AI models in hours instead of weeks

[Explore V7 Workflows ->](#)

#### BENEFITS

## Why Medical Teams choose V7

Speed up Ground Truth creation by 10 times with V7's efficient data labeling. Improve your model accuracy and automate your ML pipeline with V7's end-to-end workflow orchestration

## Volumetric Annotation

Automate and improve the accuracy and precision of your 3D medical image analysis. Get consistent results across cases.

## Consensus-Based Workflows

Compare the output of multiple models or multiple doctors against each other across your medical imaging labeling tasks.

## Annotation Authoring

Trace the history of data reviews and include annotation authorship. Make sure you meet all requirements for FDA approval.

### We conducted an extensive research of annotation tools and ultimately chose V7.

It fits our business needs best due to its customizable workflows, simple setup, consensus stages, and the ability to monitor annotator performance and project progress. It's also very intuitive and stable.

Maleeha Nawaz

Manager of Quality and Data Curation at Imidex

#### INTEGRATIONS

### Connect to anything

Host data privately in your enterprise cloud storage. Send tasks to other ML-Ops platforms once completed. Load datasets into your deep learning framework of choice in a single step.

### Solve any visual task 10x faster

Check out the annotation types that V7 offers

## Object Detection

Detect and locate the presence of multiple objects within an image, drawing bounding boxes around them to indicate their position and size. Export your labeled data in the desired format or train object detection models on V7 to label more data.

THE DATA ENGINE

## Develop your AI training data in a single ML-Ops platform

Solve any labeling task 10x faster, train accurate AI models, manage data, and hire pro labelers that care about your computer vision projects

# 21+ Best Healthcare Datasets for Computer Vision

The use of computer vision in medical imaging analysis has a plethora of benefits. The downside? Limited access to data. Check out this list of open healthcare datasets to find data faster.

## Philips Prototypes a Large-scale, Near-real-time Inference Platform to Extend Medical Imaging Using AWS

by Andrew Nader, Ilia Awakimjan, Ivo Canjels, Joost Westra, Koen de Laat, and Saswata Dash | on 25 SEP 2023 | in [Amazon Elastic Kubernetes Service](#), [Amazon Simple Queue Service \(SQS\)](#), [Healthcare](#), [Industries](#) | [Permalink](#) | [Comments](#) | [Share](#)

Image-guided therapy solutions provide visual guidance during minimally invasive therapies. However, with interventional systems

located within hospitals, enabling faster innovation and a roll-out of new technologies to the field has been a significant challenge. To solve this, [Philips](#) has prototyped a large-scale, near-real-time inferencing platform on [Amazon Web Services \(AWS\)](#) to extend the capabilities of interventionalists performing these procedures.

Integrating technological improvements for hospital-based systems, in areas such as machine learning is dependent upon expensive hardware replacements, upgrades, and application modernization. Additionally, safety-critical components of systems must stay close to the patient. With those factors in mind, enabling new features and services by first utilizing hybrid architectures that extend on-premises platforms is often the fastest way to cloud adoption and innovation.

Moving machine learning algorithms for hybrid healthcare systems into the cloud introduces several challenges: high-performance requirements, demanding availability, cost-effectiveness, and medical device regulation. With thousands of systems located in hospitals around the world, there is often unpredictable demand with near-real-time latency requirements. Implementing new features should not significantly increase costs and cloud resources must have higher levels of utilization than on-premise systems for efficiency. And, adhering to the applicable medical device regulations should still allow for achieving a high velocity of innovation and releasing of novel functionalities to the field.

By leveraging [AWS IoT](#) and [Amazon Elastic Kubernetes Service \(EKS\)](#), the strict requirements for availability and performance are met while driving the overall solution cost down when compared to modifying on-premises deployments. These technologies also enable the decoupling of non-critical components of the existing platform which permits a modern way to meet regulatory requirements.

## Philips Use Case

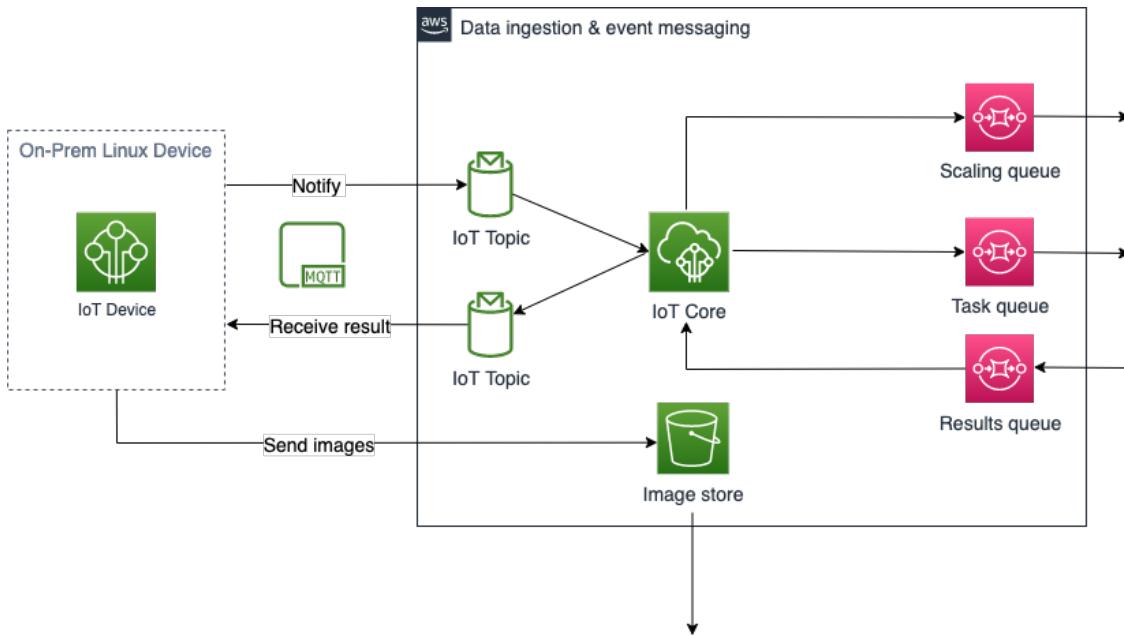


*Figure 1 – Philips Image Guided Therapy Azurion System*

Philips has image-guided systems deployed in thousands of hospitals around the world that provide real-time imaging capabilities for minimally invasive interventional procedures. To provide the best possible experience for their customers, Philips has designed a data ingestion and inferencing platform that enhances successful patient outcomes all while meeting the strict reliability and response times required for patient care.

Enhancements are achieved by leveraging the platform to execute new and existing computationally-intensive algorithms against incoming imaging data. For example, one of the algorithms used is for key event detection during angioplasty procedures. A machine learning model is used to detect when an event occurs, such as cardiovascular balloon inflation. The algorithm executes against the images that are generated when an interventionalist radiates a patient and subsequently uploaded to the cloud. It then automatically logs the event to offload tasks from the interventionalist. Feedback from the algorithm back to the hospital takes no longer than 5 seconds end-to-end.

## Implementation



*Figure 2 – Local Management, Data Ingestion and Event Messaging Architecture (Continued with Figure 3)*

### Local Management

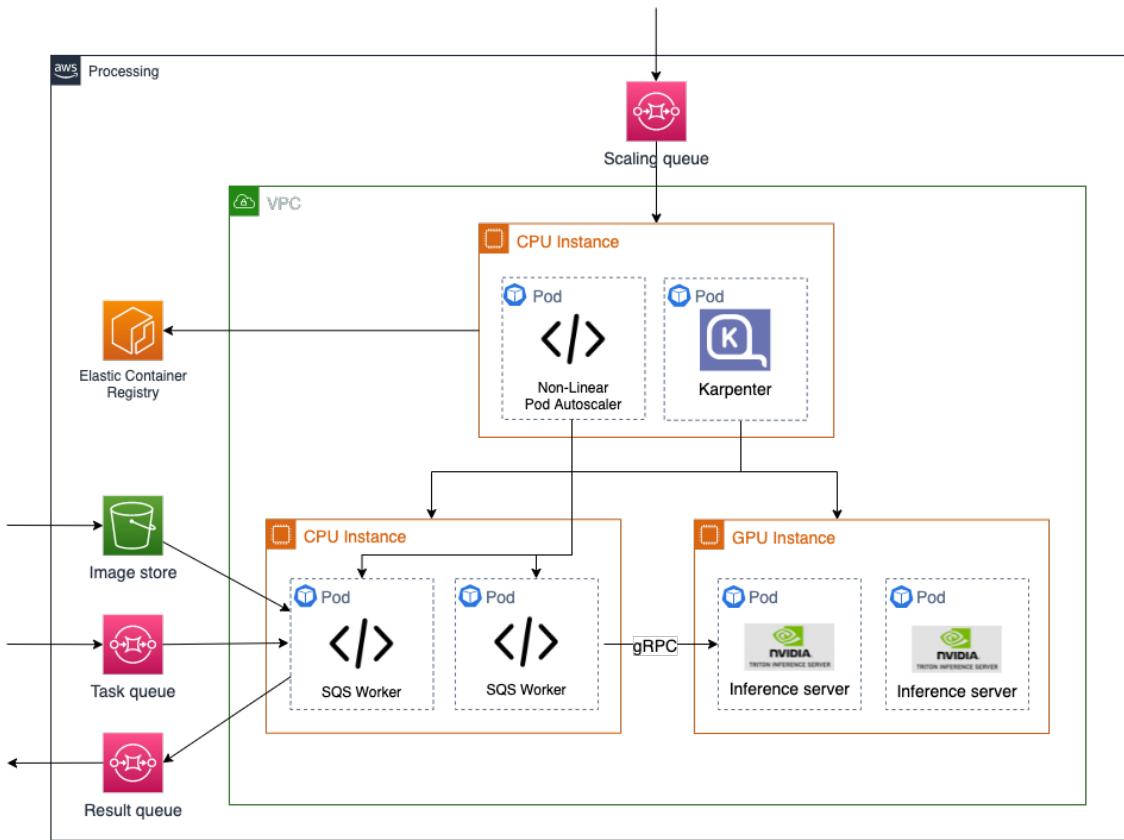
Hospital-based image-guided therapy systems are extended to the cloud by utilizing [AWS IoT](#). A lightweight, on-premise Linux device acts as a gateway for imaging data and an event generator to kickoff backend AWS processes. Additionally, AWS IoT enables remote management capabilities of the device allowing for future enhancements, including new algorithms and use cases.

### Data Ingestion & Event Messaging

To meet the strict low-latency requirements for the interventional healthcare workload, data ingestion and event messaging capabilities were decoupled, allowing for a more resilient and elastic system, as the storing of images was separated from backend processing.

Several data ingestion and storage techniques can be used depending on payload and latency requirements of the workload. However, for medical imaging with file sizes between a hundred megabytes and several gigabytes, uploading to [Amazon S3](#) using S3 Upload APIs meets the strict performance requirements and connections are stabilized further when enabling S3 Transfer Acceleration, which moves traffic off the public internet and onto the AWS edge networking backbone.

Event messaging is a critical path for developing low-latency solutions. How backend processing should be triggered by an event and how messages should be transmitted from distributed systems to the cloud are key questions to consider. Leveraging the lightweight messaging protocol, MQTT, natively supported by [AWS IoT](#) services, enables secure and reliable transmission of data. With a publish/subscribe model and small packet size, it minimizes network bandwidth usage, reduces network latency and provides low-level security required for sensitive data. Messages with information containing the location of data and how the data should be processed can be sent as IoT topics and published immediately to an [Amazon Simple Queue Service \(SQS\)](#) queue for backend mechanisms to consume. An additional benefit exists for backend processing if an algorithm requires multiple file locations as a topic could contain the necessary information.



*Figure 3 – Backend Processing Architecture (Continued from Figure 2)*

### **Processing**

The processing backbone of the platform is built on [Amazon Elastic Kubernetes Service \(EKS\)](#) as a scalable and high-performance compute platform supporting various algorithms and machine

learning use cases. Containers are deployed to monitor the [Amazon SQS](#) queue for incoming requests. Once obtaining algorithm and data location information from the task, containers responsible for computation are provisioned, utilizing the instructions to pull the required algorithm container image from an [Amazon Elastic Container Registry \(ECR\)](#) and the image data from [Amazon S3](#). For machine learning-based algorithms, Nvidia Triton is leveraged for optimization and performance. Scaling of Amazon EKS nodes and pods is proactively achieved by monitoring the size of the request queue and adding additional compute capacity as necessary utilizing a custom Non-linear Pod Autoscaler and Karpenter.

### ***GitOps***

With EKS as the core orchestration and compute platform, ArgoCD was chosen for cluster management with its intuitive GUI and dashboard. The software development lifecycle framework leverages the GitOps operational framework with the use of tools like GitHub, GitHub Actions, and ArgoCD. Infrastructure provisioning remains largely on Infrastructure as Code (IaC) functionality and resource modules, which helps with speed, scaling, and effective management. Continuous integration and delivery are managed by GitHub Actions workflows configured to automatically trigger a workflow and ensure commits are secure, syntactically correct, and pass all the pre-defined checks before merging into the main branch, thereby reducing efforts in code peer review. Error handling is directly managed from the GitHub runner, and fixed by the developer.

### **High Performance at Scale**

Most user interactions with image guided therapy systems demand near real-time end-to-end response times. The challenge with near real-time requirements, is that networking and service-introduced latencies must be consistently low, and they must remain low at scale. By leveraging the ability to test at scale, it was validated that by using Amazon S3 for its throughput and scalability, combined with AWS IoT for fast notifications to inference servers, performance requirements are able to be exceeded.

The required throughput for data ingestion with Amazon S3 is met by uploading medical images asynchronously. Once the medical images are uploaded, AWS IoT Greengrass sends an immediate MQTT message as an IoT topic and publishes to an SQS queue. An active SQS worker continually polls the SQS queues for tasks that

contained algorithm requirements and image location information. This design allows the backend inference servers to start processing with minimal delay. The most important finding when designing this architecture was that technology would not be a prohibiting factor for extending an on-premise system with high performance requirements. The only remaining limiting factor was the last-mile network connection of hospitals.

The processing of medical imagery was also marked as a potential bottleneck. However, by leveraging the flexibility of Amazon EKS to deploy both CPU and GPU based nodes, processing time is minimized by applying the proper computational footprint based on algorithm requirements. For machine learning algorithms, utilizing Nvidia Triton as the inference server optimizes performance even further by streamlining model execution for any framework on any compute infrastructure. In the future, by leveraging technology such as NVIDIA TensorRT and Amazon SageMaker Neo, algorithms can be compiled and additionally optimized to perform best on specific hardware for additional performance benefits.

The final performance results of the solution were determined only after rigorous testing at scale. Assumptions and system properties that hold true for a single user do not always remain true at load. Testing at scale highlighted several opportunities to tune the platform and remove any unforeseen issues that were not accounted for during design, highlighting the importance of this process.

## **Cost Management**

With thousands of devices in the field, remaining cost-efficient at scale is a significant challenge. If a GPU node is not available to process an incoming image request on-demand, the strict latency requirements for the solution will not be met. As a result, scaling is required before existing resources are fully utilized, balancing against the cost of overprovisioning resources. By applying statistical modelling and scaling GPU instances non-linearly with the number of devices, costs can be reduced by a factor of 30 as compared to utilizing a single GPU instance for every system in the field.

A 1:1 scaling approach that guarantees availability results in provisioning thousands of GPU nodes per region that would likely sit idle 99% of the time. One philosophy that can be utilized to scale

more cost efficiently is the acceptance of rare impact on performance. While the solution is designed for 7 nines of availability while ensuring that images are not dropped, there may be limited events at the ends of the statistical spectrum that can simply be processed with a longer than usual delay. Given that the algorithms being deployed to AWS are not in the critical path of patient safety, this is usually an acceptable user experience.

Another method that greatly reduces costs is understanding the distribution of load on the platform. As most devices in the field only intermittently send images for analysis, it is possible to serve more than one system with a single GPU. By applying non-linear scaling and the sharing of computational resources, the number of nodes required to meet the demand is exponentially reduced.

## **Regulation for Healthcare Workloads**

Life-critical medical devices are highly regulated. This is important and guarantees an appropriate level of safety for patients, but the validation processes can slow down the rate of innovation. By decoupling non-critical components from on-premise medical device monoliths, the validation effort remains local to the device, while infrastructure in the cloud benefits from a non-medical-device categorization, and algorithms that have a medical categorization can be isolated and released independently. This principle makes it possible to leverage new technologies and drive inventive improvements at a faster rate by allowing rapid development without having to revalidate the whole system for each incremental change.

## **Conclusion**

Using AWS, [Philips](#) was able to demonstrate that extending mission critical workloads to the cloud enables faster innovation that improves patient care and staff experience at a lower cost. It was also demonstrated that technology would not be a blocker for meeting strict performance and cost requirements, enabling an entirely new connected ecosystem of cloud-based technologies to enhance hospital-based systems. And, with the flexibility and portability of the platform, it can be adapted to support other modalities across the medical imaging business in the future.

# How to build a global, scalable, low-latency, and secure machine learning medical imaging analysis platform on AWS

Published 24 Aug. 2020

*This content was originally published on the [Amazon Web Services \(AWS\) Blog](#).*

## Introduction

It is hard to imagine the future for medical imaging without machine learning (ML) as its central innovation engine. Countless researchers, developers, start-ups, and larger enterprises are engaged in building, training, and deploying machine learning solutions for medical imaging that are poised to transform today's medical workflows and the future value of imaging in diagnosis and treatment.

To reach scientific breakthroughs, researchers need first to overcome several obstacles when training and deploying machine learning models. First, they must access large volumes of data stored in disjointed registries that are located in different parts of the world. Second, they need to deploy standardized tools globally to generate ground truth on reference datasets. Finally, they need to configure a secure and cost-effective environment to allow for collaboration between research groups.

That is why Diagnostic Image Analysis Group (DIAG) at the Radboud University Medical Center in Nijmegen, The Netherlands, turned to AWS to migrate their [grand-challenge.org](#) open-source platform from their on-premises data center to the cloud. [Grand-challenge.org](#) was established in 2012 for the organization of machine learning challenges in biomedical image analysis, and today brings together 45,000+ registered researchers and clinicians from all over the world to collaborate on creating novel ML solutions in the field.

When in early March 2020 it was hypothesized that CT imaging could play an important role in the diagnosis and assessment of COVID-19, the Dutch Radiological Society rapidly proposed a standardized assessment scheme for CT scans of patients with suspected COVID-19 called CO-RADS. And radiologists turned to the [grand-challenge.org](#) platform to collect imaging data and to use the platform's browser-based viewing system for CT scans to assess the performance of the CO-RADS model, which achieved a high discriminatory power for diagnosing COVID-19 from a CT scan alone (ROC 0.91, 95% CI, 0.85-0.97, for positive RT-PCR results)([1](#)).

On the platform, DIAG has made the COVID-19 dataset, the training course to teach radiologists how to assess a scan using CO-RADS, the exam and the ML model available to all registered users. However, [grand-challenge.org](#) was running in an on-premises data center, and the experience of the radiologists

using the course outside of Europe was poor due to latency of the server-side rendered viewing systems, and the number of scans DIAG could process with our AI tools was limited by the amount of hardware we provisioned before the emergence of SARS-CoV-2.

In April 2020, the collaboration between DIAG and AWS started to bring globally distributed browser-based viewing systems and elastic scaling to make these tools available to machine learning and clinical researchers worldwide. Through a successful collaboration between DIAG's Research Software Engineering team and AWS the grand challenge platform was able to be migrated to the cloud in less than two weeks from the start of the project. Several technical hurdles were overcome, resulting in a more robust, performant, and scalable application that will continue to support the medical imaging community during this pandemic and beyond.

This work presents the architecture and services used for the global medical imaging analysis platform and explains the challenges, solutions, and results obtained including 1) exchange data with the global research community, 2) low-latency and scalable web-based viewer, 3) secure and cost-effective deployment & distribution of machine learning models, and 4) rapid migration to cloud of data and compute.

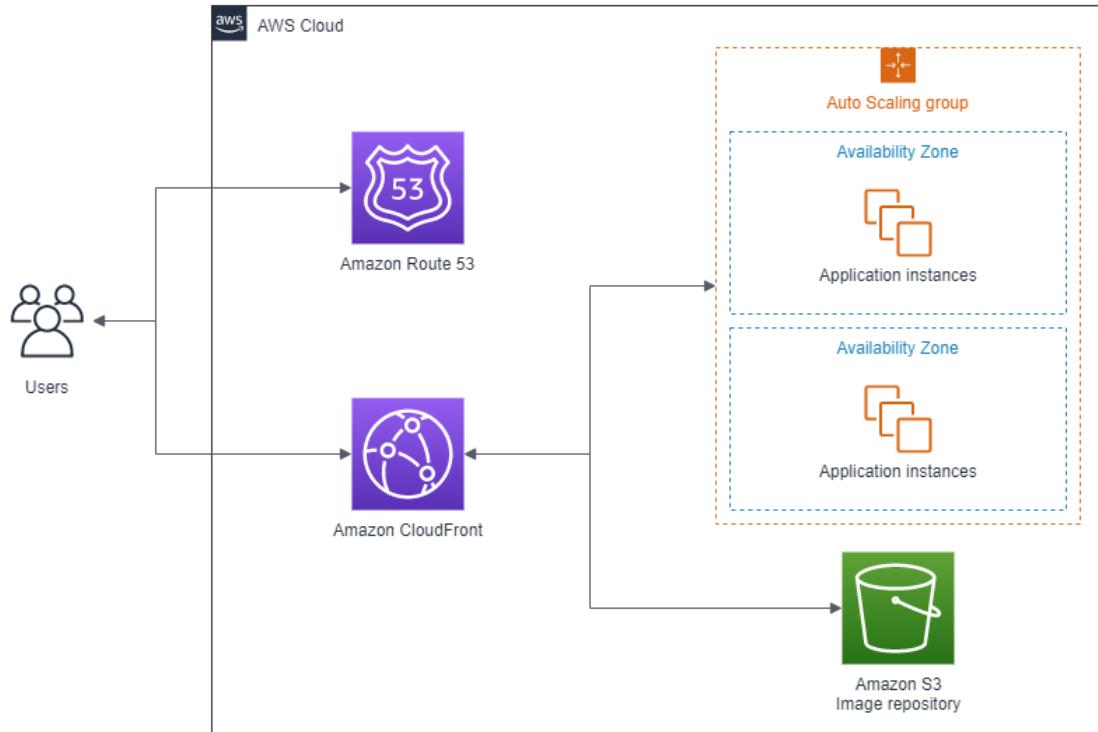
### Exchange data with the global research community

Developing robust machine learning solutions to problems in biomedical imaging requires access to large amounts of annotated training data. The volume of data generated by medical instruments such as MRI and CT scanners, next-generation sequencers, and digital pathology machines steadily increases as sensors become more accurate and systems more sophisticated in characterizing physiology. The massive data generated is locked in siloed databases and proprietary formats. The exchange of data and collaboration on research projects beyond the boundaries of an institution remains a challenge from a technical as well as compliance and security perspective.

On grand-challenge.org DIAG has added functionality so that researchers can set up archives to easily share data with each other, apply algorithms to that data, and set up their own reader studies to invite experts to annotate the data. In medical imaging, shipping HDDs across sites is the norm, but AWS enabled the use of direct upload to Amazon Simple Storage Service ([Amazon S3](#)) with accelerated transfers to gather data from sites globally. Users are able to upload data in a variety of medical imaging formats including DICOM and a variety of whole slide image formats. These data are automatically validated and converted to Metalmage or TIFF as this is much easier for the machine learning researchers to work with.

Amazon S3 is used to store all of the imaging data on the grand-challenge.org platform. Now, DIAG does not need to worry about scaling the storage after the increased data influx from scans of patients with suspected COVID-19. To allow

for fast access to the data we use Amazon CloudFront and easily integrate URL signing with the Django backend so that users are only able to download the files for the images that they have permission to view.



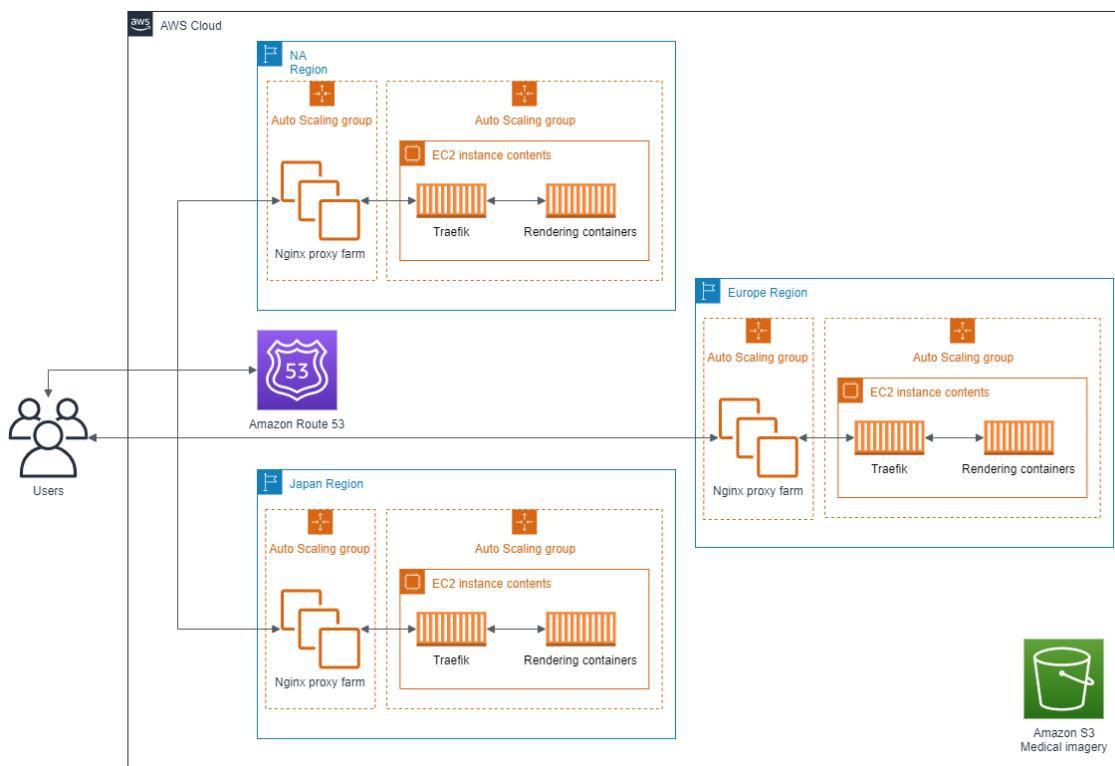
## Low-latency and scalable web-based viewer

Today, most viewing and processing of medical imaging data in both clinical and research environments happens on-premises on dedicated workstations capable of server-side rendering necessary for routine manipulations such as MIP (maximum intensity projection) viewing or 3D volumetric rendering. With the increased collaboration between radiologists from many institutions spread across the world as well as the rise in secondary usage of medical imaging for research and development of ML solutions, there is a need for globally available solutions. This challenge was faced recently by Radboud University Medical Center in Nijmegen as they received great interest from radiologists worldwide for their CO-RADS Academy solution that teaches physicians how to read COVID-19 CT images.

The Diagnostic Image Analysis Group (DIAG) developed a web-based medical imaging viewer called CIRRUS, which is built on MeVisLab from MeVis Medical Solutions. CIRRUS enables the use of many tools that radiologists require for interacting with medical imaging data. Server-side rendering is used for rapid loading of the medical imaging data and allows the use of powerful rendering hardware for 3D multiplanar reformation, pre-loading of series in memory and GPU acceleration. The rendered scenes are streamed to the client over a WebSocket connection to a VueJS single page application to also gain the strengths of client-side interactions where necessary. These workstations are

deployed using Docker containers, and one container image is launched per user with the users being routed to their container instance with Traefik.

In this project, DIAG was able to set up rendering servers on AWS in Europe, Japan, and North America on Amazon Elastic Compute Cloud ([Amazon EC2](#)). To start the container on-demand for a new user, it takes less than 30sec and we are able to horizontally scale the compute pool by adding additional EC2 instances in each Region. The medical imaging data are stored in an Amazon S3 bucket in Europe. To ensure rapid loading times in North America and the Asia Pacific Regions we used [Amazon CloudFront](#) to cache the data on demand. The loading performance for a typical 300MB CT, 500 slices CT studies is less than 10 seconds. With a latency of 20ms, there is no observer delay in scrolling, which provides a great user experience.



## Secure and cost-effective deployment & distribution of machine learning models

Researchers need to have the freedom to use whatever tool or library is most appropriate for their use case, and often find it difficult to distribute their models to the rest of the research community. On grand-challenge.org this gap is bridged by allowing researchers to upload their developed model and pre-processing pipeline as a Docker container image, where they can manage the users who can access the algorithm. This allows researchers to share their algorithms with the community, where the platform will handle authentication, authorization, data access, validation and conversion of DICOM to Metalmages, and execution of the containers on the data with GPU acceleration.

The grand-challenge.org platform uses Celery to schedule the jobs for these containers and medical images, providing GPU acceleration where needed with NVIDIA T4 cards. DIAG was able to reduce the number of services it manages by using Amazon Simple Queue Service ([Amazon SQS](#)) as the message broker and can now horizontally scale by adding workers that listen to each queue. It is also able to run across its existing provisioned hardware and during periods of increased demand start extra g4dn EC2 instances.

This has enabled researchers to rapidly deploy a model for automated scoring of CT scans with CO-RADS and is available at <https://grand-challenge.org/algorithms/corads-ai/>. Users are able to upload their own data and receive a prediction on this data within 2 minutes, and then inspect the results in the globally available browser-based workstations.

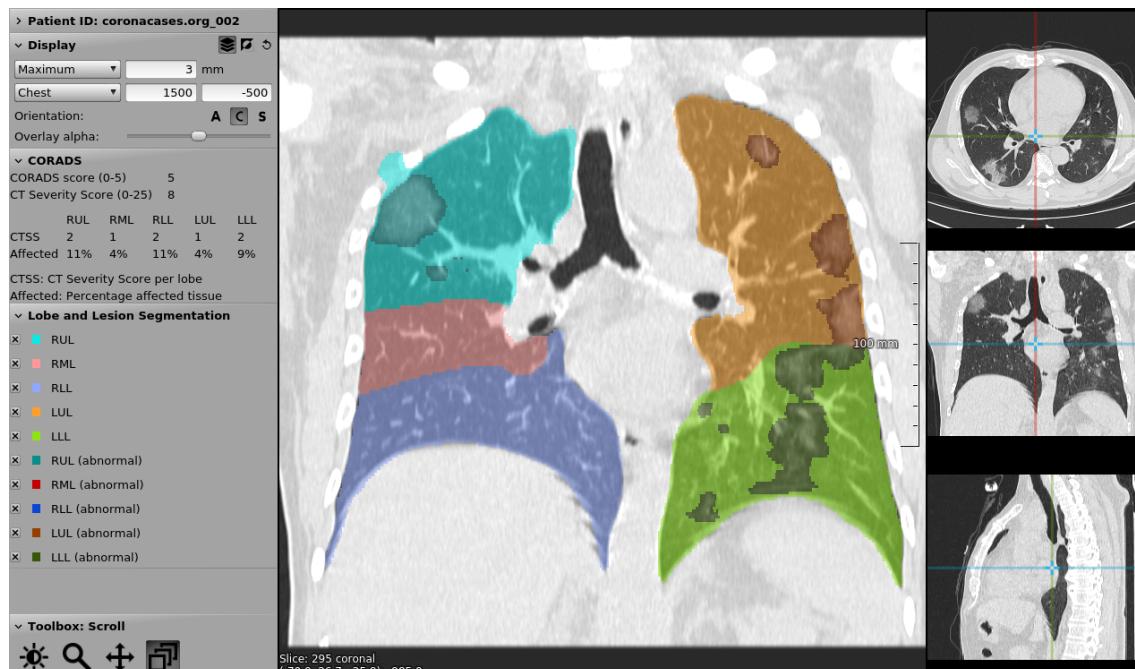


Image courtesy of Radboud University Medical Center in Nijmegen

## Rapid migration to cloud of data and compute

DIAG had previously been running grand-challenge.org in its on-premises data center, and did not foresee the scale at which it would need to operate during this pandemic. However, when developing the application DIAG had the cloud in mind, and tried to ensure that workloads were mobile. The team at DIAG uses the 12 Factor App methodology, has robust CI/CD pipelines that distribute the application as a set of Docker images, provision bare metal and VM instances with Ansible, and used Minio to abstract the on-site storage with the Amazon S3 API.

Using AWS services, DIAG was able to rapidly move this workload to the cloud. Several terabytes of imaging data were synced in place using Amazon S3 sync, so that switching over the storage backend was a case of changing environment variables. The team was also able to move the database to a managed Postgres

RDS instance and the Celery broker from Redis to Amazon SQS to reduce the ops burden. Moving this workload to AWS has allowed for scale on-demand, based on the unpredictable demand during this pandemic.

## Research results and future work

Recently, the group at Radboud University Medical Center together with numerous collaborators published the results of the CORADS-AI, a system that consists of three deep learning algorithms that automatically segment the five pulmonary lobes, assign a CO-RADS score for the suspicion of COVID-19 and assign a CT severity score for the degree of parenchymal involvement per lobe<sup>(2)</sup>. The system was tested on 105 patients ( $62 \pm 16$  years, 61 men) and 262 patients ( $64 \pm 16$  years, 154 men) internal and the external cohorts, respectively. The system discriminated between COVID-19 positive and negative patients with areas under the ROC curve of 0.95 (95% CI: 0.91-0.98) and 0.88 (95% CI: 0.84-0.93). [CORADS-AI](#) has been deployed on the AWS platform and it is now available for other researchers.

One of the future goals of grand-challenge.org is to allow users to submit their custom algorithms to run in GPU accelerated hardware in the cloud. This code needs to run in an isolated, secure environment, and users should preferably be able to either use Docker images provided by grand-challenge.org, or their own images. A solution is currently being developed that makes use of AWS Batch as a job scheduler. A web application will let the users interact with a fully serverless backend built on top of AWS Lambda, Amazon DynamoDB, and Amazon API Gateway, to enable them to submit their jobs and manage their results.

Amazon ECR will store container images. A CI/CD pipeline built on top of the AWS CodePipeline service will follow, that will allow users to submit their Dockerfile to have them automatically built and stored in Amazon ECR.