

Aplicando algoritmos de Inteligência Artificial para melhorar os resultados e planejar o crescimento em um hospital



André Schwartzman
andre@discoveryconsultoria.com.br

www.discoveryconsultoria.com.br

“Estamos nos afogando em informações, mas sedentos por conhecimento.”

- John Naisbitt



Introdução

No ano de 2001, um hospital localizado na cidade de São Paulo iniciou um trabalho de pesquisa e cruzamento de informações em suas bases de dados, para criar perfis detalhados de seus pacientes, setores e serviços mais lucrativos e daqueles menos lucrativos.

O estudo tinha como objetivo

identificar dados valiosos que pudessem auxiliar na definição de ações comerciais e financeiras, no planejamento de investimentos e na definição de áreas para futuro crescimento. Embora o lucro não seja o único direcionador das decisões de um hospital, é evidente que, no longo prazo, se a instituição adotar opções estratégicas financeiramente indesejáveis, sua sobrevivência poderá estar em risco.

Como em muitas outras empresas, existiam vastas quantidades de informações nos bancos de dados do hospital. Diversos anos de registros de movimentação de pacientes estavam armazenados. Devido ao volume de dados e à quantidade de características a serem analisadas, decidiu-se utilizar ferramentas de Inteligência Artificial para as análises. A conceituação das ferramentas utilizadas encontra-se nas páginas a seguir. Também serão detalhadas a forma como o hospital conduziu o trabalho, as principais conclusões e lições aprendidas durante o projeto.

Um problema comum: Como melhorar as margens e o lucro?

Como em outras indústrias, no setor hospitalar existem especialidades e serviços que são considerados tipicamente mais lucrativos do que outros. Em geral, acredita-se que pacientes cirúrgicos são mais lucrativos do que aqueles que somente utilizam a internação sem passar por cirurgia. Da mesma forma, pacientes que passam pelas unidades de terapia intensiva são mais lucrativos, pois o valor agregado por dia de permanência é maior. Também se acredita que pacientes que permanecem internados poucos dias são mais lucrativos do que aqueles de longa permanência, pois é nos primeiros dias da internação que os pacientes recebem a maior quantidade de procedimentos, materiais e medicamentos, itens que agregam maior margem financeira do que a simples diária hospitalar.

Essas noções genéricas são importantes, porém insuficientes para a tomada de decisões. Será que elas são válidas, dada a realidade, público-alvo e região de atuação do hospital? Mesmo sendo válidas, qual é a diferença quantitativa entre um tipo de cliente e outro? Será que outras características, tais como especialidade, diagnóstico, tipo de plano de saúde, idade, ou qualquer outra característica, também influenciam de maneira consistente e significativa o nível de lucratividade? Obter as respostas para estas perguntas motivou este trabalho.

A Inteligência Artificial e o aprendizado de máquina

Nas últimas décadas, temos vivido um crescimento explosivo na nossa capacidade de gerar e coletar dados. A informatização de muitas atividades possibilitou a captura, em tempo real, de largas quantidades de informações e transações. A evolução da tecnologia de armazenagem de dados, aliada a melhores sistemas de gerenciamento de bancos de dados, possibilitou transformar esse volume de informação em montanhas de dados armazenados.



Métodos tradicionais de pesquisa de informações, como análise em planilhas, gráficos e tabelas, tornam-se inadequados diante de tamanha quantidade de dados e do número de padrões que podem ser descobertos. Passa a existir, portanto, uma necessidade de uma nova geração de técnicas e ferramentas com a habilidade de ajudar os seres humanos de maneira inteligente e automática a analisar grandes massas de dados, em busca de conhecimento útil.

Entendendo a nomenclatura

Inteligência Artificial é o termo utilizado para se referir às máquinas que são capazes de executar tarefas normalmente associadas à inteligência humana. O *aprendizado de máquina* (do inglês *machine learning*) é um subconjunto da Inteligência Artificial, abrangendo sofisticados algoritmos computadorizados capazes de identificar padrões em grandes volumes de dados, para resolver problemas e fazer previsões de forma autônoma. Os algoritmos de aprendizado de máquina diferem de outras formas de análise por não requererem a formulação de uma consulta específica ou a definição de um modelo estatístico a priori.

A Inteligência Artificial, em especial o aprendizado de máquina, é um esforço conjunto entre seres humanos e computadores. Os seres humanos projetam bancos de dados, descrevem os problemas e definem os objetivos. Computadores vasculham então os dados, buscando identificar padrões relacionados aos objetivos definidos. Neste processo de busca, são utilizados programas de computador especialmente projetados para lidar com vastas quantidades de informação da maneira mais automática possível.

Como uma máquina aprende?

Os padrões que precisam ser descobertos em um banco de dados muitas vezes estão relacionados às *categorias* às quais diferentes situações pertencem. Por exemplo, uma pessoa é merecedora de crédito para obter um financiamento ou não? Um certo segmento de população irá responder a uma mala direta ou não? A bolsa de valores irá subir ou cair no mês que vem? Tecnicamente, em termos de aprendizado de máquina, estas são tarefas de *classificação*.

A forma mais comum de se lidar com tarefas de classificação é inicialmente extrair do banco de dados uma amostra representativa de *casos*. Cada caso é um registro completo de diversas *características*. Cada caso utilizado contém também o *resultado real* de cada situação. Por exemplo, uma utilização comum do aprendizado de máquina é a avaliação do risco de crédito em empréstimos bancários. Os bancos mantêm registros históricos detalhados de seus empréstimos. Os critérios utilizados para se avaliar o risco de um empréstimo são descritos em termos de características. Estas características incluem, por exemplo, informações sobre a

condição financeira do interessado, seu histórico de crédito e outras. Um caso é um registro completo de um empréstimo efetuado. O histórico de cada empréstimo é mantido atualizado, indicando se o empréstimo foi quitado em dia ou não.

No exemplo acima, o objetivo é identificar os critérios de decisão que indicam se um novo empréstimo deverá ser concedido ou não. Caso as características do interessado o coloquem na mesma categoria daqueles que não costumam honrar seus empréstimos, o banco deverá rejeitar a concessão do empréstimo para este interessado. Por outro lado, caso as características do interessado o coloquem junto à categoria daqueles que no passado honraram seus compromissos junto ao banco, a instituição poderá conceder o empréstimo.

Métodos utilizados no aprendizado de máquina

A maioria dos métodos de aprendizado de máquina está baseada nos conceitos de reconhecimento de padrões e estatística. Os métodos podem ser agrupados, de maneira genérica, em soluções matemáticas, soluções de distância e soluções lógicas. Dentro de cada grupo existem diversos métodos e técnicas aplicáveis.

Dentro desse universo, três métodos se destacam. *Redes neurais*, *árvores de decisão* e *regras de decisão* representam as técnicas mais utilizadas dentre os métodos desenvolvidos ao longo das últimas três décadas de pesquisa. A escolha do método a ser utilizado é uma das decisões mais importantes dentro do processo de aprendizado de máquina. O quadro abaixo sumariza algumas das principais características destas técnicas.

REDE NEURAL
Modelo matemático não linear, capaz de modelar as mais diversas funções e resolver problemas de regressão e de classificação. Pontos negativos desta técnica incluem longos períodos para treinamento e dificuldade de interpretação da solução. Os critérios de decisão frequentemente são desconhecidos no caso das redes neurais, pois a representação matemática complexa não se presta a uma tradução em regras facilmente interpretáveis pelos seres humanos.
ÁRVORE DE DECISÃO
Um dos mais importantes e mais utilizados métodos lógicos de classificação. A solução é representada através de uma árvore lógica de decisão. A indução da árvore costuma ser muito rápida. Ao contrário das redes neurais, as regras de decisão são claras e explícitas, o que permite compreender e estudar a solução. Um ponto negativo desta técnica é o tamanho da árvore, que pode se tornar muito grande e com muitos níveis, dificultando a interpretação.
REGRAS DE DECISÃO
Da mesma forma que a árvore de decisão, é um método lógico de classificação. A solução é representada por um conjunto de regras do tipo "Se ... então ...". A qualidade e rapidez da solução é comparável à da árvore de decisão, com a vantagem de, para problemas mais complexos, ser muito mais compacta e facilmente interpretável.

Para algumas tarefas de aprendizado de máquina, o objetivo é classificar novos casos da forma mais precisa possível. Nestes casos, qualquer uma das três técnicas acima pode ser utilizada. Entretanto, nas tarefas onde é importante a interpretação da solução, as árvores de decisão e as

regras de decisão assumem papel de destaque. Este é o caso no trabalho desenvolvido no hospital. A seguir detalharemos essas duas ferramentas.

Árvores e regras de decisão

Devido à importância que as árvores de decisão e as regras de decisão assumem num processo de aprendizado de máquina, ilustraremos sua utilização através de um exemplo.

Ensinando regras de divisão para uma máquina

Vamos criar um banco de dados com os números inteiros positivos de um a 100. Para cada um destes números, são conhecidas as características de divisibilidade por dois, três, quatro e cinco. O banco de dados tem o seguinte formato:

	CARACTERÍSTICAS				RESULTADO	
	Número	Divisível por 2?	Divisível por 3?	Divisível por 4?	Divisível por 5?	Divisível por 6?
caso 001	1	não	não	não	não	NÃO
caso 002	2	sim	não	não	não	NÃO
caso 003	3	não	sim	não	não	NÃO
caso 004	4	sim	não	sim	não	NÃO
caso 005	5	não	não	não	sim	NÃO
caso 006	6	sim	sim	não	não	SIM
caso 007	7	não	não	não	não	NÃO
caso 008	8	sim	não	sim	não	NÃO
caso 009	9	não	sim	não	não	NÃO
caso 010	10	sim	não	não	sim	NÃO
caso 011	11	não	não	não	não	NÃO
caso 012	12	sim	sim	sim	não	SIM
...
...
caso 096	96	sim	sim	sim	não	SIM
caso 097	97	não	não	não	não	NÃO
caso 098	98	sim	não	não	não	NÃO
caso 099	99	não	sim	não	não	NÃO
caso 100	100	sim	não	sim	sim	NÃO

O resultado que estamos estudando é a divisibilidade por seis. Ou seja, desejamos criar regras automáticas que nos informem se um *novo* número, não presente na tabela, é divisível por seis. Na última coluna da tabela acima, podemos notar que os números divisíveis por seis (6, 12, e assim por diante, até 96) estão identificados através de um “SIM”.

No caso 001, analisamos as características do número um. Este número não é divisível por dois, três, quatro ou cinco. O resultado deste caso é negativo: o número um não é divisível por seis. O nosso banco de dados analisa estas mesmas informações para todos os números inteiros até 100.

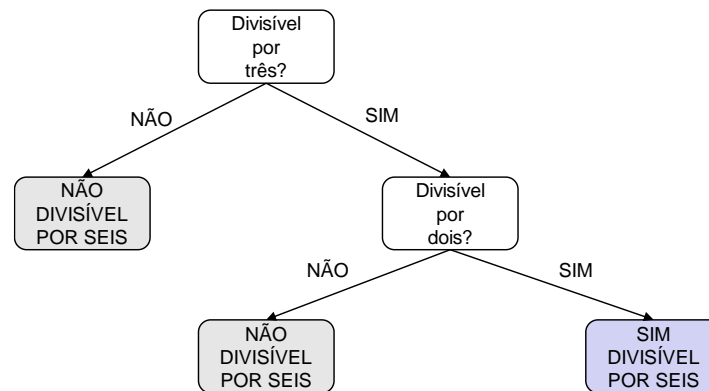
Árvore de decisão

A árvore de decisão que soluciona este problema é a seguinte:

```
Decision tree:
Divisível por 3 = nao: NAO DIVISIVEL POR 6 (67)
Divisível por 3 = sim:
: ... Divisível por 2 = sim: SIM DIVISIVEL POR 6 (16)
      Divisível por 2 = nao: NAO DIVISIVEL POR 6 (17)
```

O número entre parênteses que se segue a cada linha acima indica o número de casos que se encaixam em cada nóculo de decisão. No nosso exemplo, dos 100 casos, 67 não são divisíveis por três; nenhum destes é divisível por seis. Dezesesseis casos são divisíveis por três e também divisíveis por dois; todos estes casos são divisíveis por seis. Por último, dos casos divisíveis por três, dezessete não são divisíveis por dois; nenhum destes é divisível por seis.

A seguinte figura ilustra esta árvore:



A árvore de decisão corretamente identifica duas características, a divisibilidade por dois e a divisibilidade por três, como os únicos determinantes da divisibilidade por seis. As outras características foram descartadas, por não acrescentarem mais informação à solução.

Regras de decisão

A mesma solução é possível através de uma única regra de decisão:

```
Rule 1: (16)
  Divisível por 2 = sim
  Divisível por 3 = sim
  -> class SIM DIVISIVEL POR 6
```

A regra acima pode ser traduzida para nossa linguagem da seguinte forma: se um número for divisível por dois e também for divisível por três, então ele pertence à classe dos números divisíveis por seis. Existem 16 casos (dos 100 apresentados) que se encaixam nesta regra.

A árvore de decisão e as regras de decisão são criadas automaticamente pelos algoritmos de aprendizado de máquina. Os modelos automaticamente identificam as variáveis relevantes e descartam as demais.

Aplicações em problemas da vida real

É fácil entender o papel de destaque que estes métodos assumiram na análise de dados, quando se alia o poder de extrair regras precisas e interpretáveis à capacidade de lidar com centenas de milhares (ou mesmo milhões) de casos, milhares de variáveis e até mesmo dados incompletos ou faltantes.

Evidentemente, problemas encontrados na vida real não possuem soluções tão simples quanto no exemplo acima. Para as situações que envolvem maior complexidade e incerteza, os métodos de aprendizado de máquina possuem ferramentas adicionais para aumentar a precisão dos modelos e garantir que uma solução encontrada seja válida para novos casos.



Da Teoria à prática: Os desafios do hospital

Compreendidas as ferramentas básicas, vamos agora ver como o hospital aplicou estes conceitos para buscar respostas às questões levantadas anteriormente.

Objetivos do estudo

Os principais objetivos do estudo podiam ser resumidos nos seguintes pontos:

- Entender, de maneira detalhada, exatamente quais eram as características que determinavam o resultado financeiro do hospital;
- Entender quais eram as oportunidades para melhorar tais resultados a curto, médio e longo prazo;
- Criar perfis detalhados para os pacientes mais lucrativos e para os pacientes menos lucrativos;
- Ajudar a identificar oportunidades e estratégias para ações comerciais e financeiras;
- Auxiliar no planejamento de investimentos e na definição de áreas para futuro crescimento.

O primeiro desafio foi verificar quais dados estavam disponíveis nos bancos de dados e, acima de tudo, se eles eram adequados para a tomada de decisão.

Neste caso, os dados estavam em distintos sistemas e bases de dados. Foi necessário cruzar diversas informações das bases de faturamento, estoques, clientes e outras. O maior desafio, no entanto, foi definir como medir o resultado real de cada atividade e de cada cliente.

Por exemplo, um dos objetivos era entender os perfis de lucratividade dos pacientes. Foram necessários diversos estudos para se definir como calcular isso, uma vez que essa era uma informação gerencial que não estava disponível nos bancos de dados. O passo seguinte foi preparar o terreno para estudar as características desses grupos.

A partir de diversas bases de dados com centenas de milhares de registros, criou-se uma única tabela contendo aproximadamente 65 mil linhas, consolidando informações de custos e receitas para os diversos tipos de lançamentos para cada conta hospitalar (taxas, materiais, medicamentos, honorários médicos, exames etc.). Essa tabela foi novamente processada,

consolidada e cruzada com os dados cadastrais de cada paciente. Foram selecionadas apenas as informações dos setores sendo estudados. A amostra final continha pouco menos de 10 mil casos. Considerando que a tabela possuía cerca de 30 características, havia um total de quase 300 mil informações distintas que deveriam ser cruzadas e analisadas.

Cada caso representava um único paciente e continha informações em três grandes categorias. *Informações cadastrais* descreviam características de cada paciente, como sexo, idade e plano de saúde. *Informações médicas* descreviam características dos procedimentos e diagnósticos efetuados. *Informações financeiras* possibilitavam o cálculo da lucratividade de cada paciente.

Para cada paciente, utilizou-se como medida de lucratividade a *margem de contribuição* acumulada ao longo de sua permanência no hospital. Esta margem de contribuição foi então dividida pelo número de dias de permanência, obtendo a *margem por dia de permanência*. Por último, os casos foram divididos em dois grupos: o grupo de alta lucratividade e o grupo de baixa lucratividade.

O potencial de melhoria

No estudo de lucratividade por paciente, a diferença entre os grupos de alta e baixa lucratividade era significativa. A margem de contribuição diária de um paciente de alta lucratividade era quase 4 vezes maior do que a dos demais. O total de contribuição financeira deste pequeno grupo de pacientes era quase igual ao total de contribuição dos demais pacientes, sendo que estes últimos representavam mais de 80% de todo o movimento do hospital.

O hospital operava, na maior parte dos setores, próximo ao limite de capacidade. A cada paciente de alta lucratividade que o hospital atendesse, a margem diária aumentaria em 300% por dia para cada leito!

Análises e conclusões

Os estudos iniciais revelaram informações de grande interesse. De um lado, algumas das crenças que o setor administrativo do hospital possuía sobre lucratividade dos pacientes foram validadas. Por outro lado, começou-se a compreender os direcionadores da lucratividade de uma maneira mais detalhada do que se imaginava possível.

Foram realizados diversos estudos, cada qual trabalhando com conjuntos distintos de características. O primeiro estudo confirmou que, dentre todas as características, as que mais influenciam a lucratividade são o tempo de internação, o fato do paciente ser cirúrgico e o fato do paciente passar pela unidade de terapia intensiva (UTI). O algoritmo de Inteligência Artificial forneceu as regras exatas. Apenas quatro regras classificam todos os casos. As regras que identificam os pacientes de alta lucratividade são as seguintes (nesta seção, regras que identificam as características de alta lucratividade estão em azul, e regras que identificam as características de baixa lucratividade estão em vermelho):

```
Rule 1:
    Passou pela UTI = sim
    Dias de Internacao = 1
    -> class ALTA LUCRATIVIDADE
Rule 2:
    Cirurgico ou Clinico = Cirurgico
    Dias de Internacao = 1
    -> class ALTA LUCRATIVIDADE
```


Analisando a Regra 1, é interessante observar que para que um paciente de UTI esteja entre os de alta lucratividade, ele deve permanecer internado somente por um dia. A mesma consideração pode ser feita em relação à Regra 2: pacientes cirúrgicos estão entre os mais lucrativos, desde que eles permaneçam apenas um dia no hospital.

Até aqui, não utilizamos plenamente a capacidade de processamento dos algoritmos de Inteligência Artificial. Deliberadamente restringimos a quantidade de características sendo estudadas. No estudo seguinte, alimentamos toda a base de dados para que a máquina aprendesse quais características determinavam a lucratividade de cada atendimento.

As análises subsequentes trabalharam com outros conjuntos de características, buscando identificar em detalhes as características dos pacientes, especialidades e planos de saúde mais lucrativos. Foram descobertas especialidades que tendem a ter casos de alta lucratividade. Em determinadas situações, a especialidade precisa também ser combinada com um paciente cirúrgico para que apresente alta lucratividade. Ainda em outros casos, existe a influência de características do paciente, como a idade.

(Observação: a partir daqui, apresentaremos as análises feitas no hospital através de trechos das árvores e regras de decisão. Por confidencialidade, algumas alterações foram efetuadas nas regras, sem prejudicar seu caráter ilustrativo.)

Algumas das análises feitas pelo algoritmo indicaram recorrente baixa lucratividade em alguns setores, especialidades e diagnósticos (indicados aqui pelo código CID, ou a Classificação Internacional da Doença), como por exemplo:

```
Rule 21:
    CID2 = K35
    -> class BAIXA LUCRATIVIDADE
Rule 22:
    CID2 = J18
    -> class BAIXA LUCRATIVIDADE
Rule 23:
    CID2 = J93
    -> class BAIXA LUCRATIVIDADE
Rule 24:
    CID2 = R10
    -> class BAIXA LUCRATIVIDADE
```

Nos casos acima, novas análises indicaram características ainda mais detalhadas, relacionadas ao convênio médico, plano de saúde, equipe médica e até mesmo o médico diretamente identificado pelos algoritmos de Inteligência Artificial. Ações decorrentes dessas análises incluíram:

- revisão dos custos internos para aumento da lucratividade associada aos serviços e setores envolvidos;
- renegociação com fornecedores, prestadores de serviço e convênios;
- criação de controles informatizados para evitar situações identificadas nas quais algumas atividades eram efetuadas com prejuízo;
- a longo prazo, decisões de quais especialidades não poderiam ser atendidas com rentabilidade suficiente pelo hospital e que, portanto, precisariam ser reduzidas, eliminadas ou profundamente reformuladas com base em melhores práticas do mercado.

Outras análises através de árvores de decisão ajudaram a identificar oportunidades bastante interessantes. Elas forneceram um profundo detalhamento das características que determinam a lucratividade, trazendo informações que eram desconhecidas por parte dos gestores do hospital. Abaixo alguns trechos da árvore de decisão:

```
Decision tree:
Cirurgico_ou_Clinico = Cirurgico:
: ... CID2 in K44, I50, M65, S83, S06, C40, Z98, S52, P76, C76, O86, M25, S02, J16, N23, N83,
:   H26, S81, K83, M48, J34, T00, Q69, T07, N47, S64, R59, T13, K56, S62, R56, K42,
:   N17, I61, N92, S54, M22, J35, S93, O06, K30, R57, K46, J45, K20, P23, G91, S04,
:   D40, M23, G56, N30, T79, D63, N64, G55, N20, D18, Q54, G57, R61, C68, L91, T14,
:   Z93, D09, M66, S74, M70, Q90, L72, L97, N36, L04, J84, R42, Q62, G60, N71,
:   J36: ALTA LUCRATIVIDADE
CID2 in K92, D25, J18, J15, S42, R52, I83, S72, Z37, K59, S82, R10, I21, Q50, K60, A09,
:   K25, S01, Z51, J03, I20, S92, N39, R51, N63, N84, R32, N18, O03, L05, R60, F10,
:   R50, K29, L03, N13, M67, D07, K35, T18, C50, H83, I15, C18, C79, Q39, B01, N21,
:   R04, N81, M75, E88, T12, J90, I84, O82, O90, C47, N51, N40, K61, S69, D26, C61,
:   M71, M76, K85, R17, N43, J93, A46, I69, O00, D29, O83, N45, A08, S09, R64, D64,
:   C25, B69, I10, K63, I60, Q52, E46, I63, K80, N35, M86, K43, S00, N46, D28, C32,
:   D17, A64, J01, G47, S68, N62, S91, K52, K62, I81, L02, M79, T68, C54, T06, Z32,
:   O68, D04, F50, D39, O62, N96, O08, L98, S80, T25, I31, R55, O80, T17, M12, M13,
:   Z01: BAIXA LUCRATIVIDADE
CID2 = R22:
: ... Idade <= 26: BAIXA LUCRATIVIDADE
:   Idade > 26: ALTA LUCRATIVIDADE
CID2 = G45:
: ... Plano in [SEGUEM NOMES DE 4 PLANOS DE SAÚDE]: BAIXA LUCRATIVIDADE
:   Plano in [SEGUEM NOMES DE 2 PLANOS DE SAÚDE]: ALTA LUCRATIVIDADE
CID2 = K81:
: ... Especialidade in [SEGUE LISTA DE 5 ESPECIALIDADES]: ALTA LUCRATIVIDADE
:   Especialidade = [SEGUE LISTA DE 2 ESPECIALIDADES): BAIXA LUCRATIVIDADE
CID2 = K40:
: ... Idade <= 6: ALTA LUCRATIVIDADE
:   Idade > 6: BAIXA LUCRATIVIDADE
```

Validando as análises

Estudos semelhantes aos acima foram feitos, com dados coletados ao longo de períodos de tempo distintos. A validação das análises foi um passo importante, envolvendo equipes multidisciplinares. Essas mesmas equipes ficaram responsáveis por elaborar planos de ação para capturar as oportunidades validadas.

Além dos critérios de classificação reproduzidos nos quadros acima, adicionalmente os algoritmos de aprendizado de máquina informam também a *precisão* e a *abrangência* de cada regra.

A abrangência é uma informação essencial, pois ela indica o universo de casos que cada regra abrange. Algumas regras apresentam elevada probabilidade de acerto, porém abrangem somente alguns casos relativamente raros. Outras regras abrangem uma grande quantidade de casos. O número de pacientes e de atendimentos cobertos por cada regra é informação valiosa

para planejar mudanças nos serviços e nas especialidades, já sabendo de antemão quantos pacientes por dia são atingidos por cada regra de decisão.

Ambas as informações – precisão e abrangência – foram analisadas em conjunto com os critérios de classificação pelas diversas equipes no hospital. Somente essa análise completa permitiu elaborar planos de ação que capturaram as oportunidades, trazendo melhorias significativas e rápidas e maximizando o retorno sobre o investimento deste projeto.

Este foi só o começo

O foco deste texto está no detalhamento das técnicas de análise e identificação das oportunidades e estratégias de melhoria, com o uso das ferramentas de Inteligência Artificial, em particular de aprendizado de máquina.

Os objetivos de negócio, entretanto, somente são atendidos com a efetiva transformação da empresa. Para tanto, as hipóteses de melhoria descobertas com a ajuda dos algoritmos precisam se converter em *decisões* e *ações* empresariais. Estas ações incluem atividades que geram impacto positivo em diversos horizontes de tempo.

Após finalizadas as análises descritas acima, o hospital iniciou uma série de projetos de transformação, que acabaram por envolver colaboradores, equipes médicas, parceiros, fornecedores e clientes. Somente com uma execução cuidadosa é que foi possível colher os frutos de diversas oportunidades identificadas nas análises acima.

Os gestores do hospital consideraram que os estudos tiveram sucesso em trazer novas descobertas em um formato que claramente direcionou as ações para aumentos significativos de lucratividade em diferentes setores e especialidades. Além desses ganhos de curto prazo, no longo prazo o hospital obteve informações valiosas para planejar seus investimentos e direcionar seu crescimento.



Lições aprendidas

A iniciativa de aplicação de algoritmos de Inteligência Artificial no hospital trouxe um processo de aprendizado importante. A tomada de decisões com base em dados e evidências requer uma receptividade por parte das pessoas que terão que alterar suas rotinas e estratégias. Da mesma forma, o uso de ferramentas de Inteligência Artificial é um processo novo, que requer estudo e investimentos.



Algumas dicas que foram úteis para o sucesso do projeto estão listadas a seguir.

- ✓ Antes de iniciar os trabalhos, promova reuniões e debates a respeito de como as pessoas tomam decisões. Discuta sobre a importância da análise dos dados para a tomada de decisões bem informadas. Discuta sobre os possíveis motivos pelos quais as pessoas podem resistir a um projeto com este: confiar mais na observação e experiência individual do que nas análises e nos dados; ficar na “zona de conforto” das habilidades de cada um; tendência a acreditar em dogmas, crenças e ideologias.
- ✓ Defina claramente o objetivo do estudo. Antes de iniciar qualquer trabalho de coleta de dados, decida como o conhecimento obtido poderá ser utilizado.
- ✓ Estude detalhadamente os bancos de dados da empresa. Não perca tempo coletando informações que podem ser extraídas ou transformadas a partir de fontes já disponíveis.
- ✓ Sempre questione a confiabilidade dos dados antes de iniciar qualquer estudo. Caso o dado não seja confiável, substitua-o por outro. Caso seja necessário, colete os dados novamente.
- ✓ Conheça o processo pelo qual os dados são coletados. Acompanhe o processo e identifique falhas. Faça auditorias. Como em qualquer projeto envolvendo sistemas de informação, vale a regra “entra lixo, sai lixo!”
- ✓ Faça pesquisas por artigos e publicações envolvendo a aplicação da Inteligência Artificial na sua indústria ou setor. Entre em contato com especialistas.
- ✓ Não acredite que as ferramentas de Inteligência Artificial farão mágica. Elas funcionam, em grande parte, como uma análise estatística bastante sofisticada. Por mais robustos que os algoritmos sejam, o ser humano é quem precisa definir as variáveis de interesse, garantir que elas capturam corretamente a dinâmica interna e externa da empresa (operacional, comercial, financeira, mercado e concorrência) e definir uma forma consistente de avaliar os resultados de forma a possibilitar a tomada de decisão bem informada.

A Inteligência Artificial não substitui a Inteligência Humana, em particular a visão de negócio dos gestores e de quem lida com os problemas no dia a dia da empresa.

Sobre o autor

André trabalha há mais de 25 anos com gestão de empresas, turnaround, reestruturação e melhoria de performance, tendo ocupado cargos executivos em empresas de grande e médio portes, em diversos setores.

André foi o sócio líder da área de Reestruturação de Empresas da KPMG no Brasil, sendo responsável por desenvolver e liderar as práticas de Turnaround, Cash Management, Reestruturação Financeira e Operacional e Recuperação Judicial. Durante seus anos na KPMG, André teve a oportunidade de participar de alguns dos maiores projetos no Brasil em diversos setores tais como infraestrutura, agronegócio (incluindo frigoríficos, açúcar e álcool, soja, café, frutas), alimentos e bebidas, automobilístico, educação e varejo. Antes da KPMG, André foi o Controller da Infinity Bio-Energy S/A, Controller da Parmalat Brasil S/A, CFO do Instituto Iguatemi de Clínicas e Pronto-Socorro S/A e CFO do Mappin Telecomunicações.

Como consultor, André participou de projetos de gestão e melhoria de performance em diversas empresas, incluindo Malwee, Etna, Vivara, Glencore, Vitopel, Cotia Trading, Dedini, Cofap, Mangels, Alcoa, Mannesmann, Durex, Caloi, Fiat, Plascar e Soplast.

André obteve seu Post-MBA pela Northwestern University – Kellogg School of Management, seu MBA Executivo pela Fundação Dom Cabral, sua pós-graduação executiva na UCLA – University of California, Los Angeles. Formado em Administração de Empresas pela FGV – Fundação Getúlio Vargas, São Paulo.

André é o sócio fundador da Discovery Consultoria.

A Discovery Consultoria

A Discovery Consultoria se especializa em aplicar algoritmos de Inteligência Artificial para melhorar vendas, capital de giro, lucro e valor das empresas de serviços, indústria e comércio. Os projetos trazem importantes melhorias em ritmo acelerado, que não seriam possíveis sem o uso destas ferramentas.

A metodologia utilizada pela Discovery é proprietária e foi desenvolvida no decorrer de vários anos de experiência no mercado, atuando em empresas de pequeno, médio e grande porte com um único propósito: melhoria de performance empresarial. Todas as análises utilizam dados transacionais sobre compras, vendas, estoques, custos e despesas, já existentes nos bancos de dados da empresa, que são complementados com informações sobre mercado, estratégia e uma metodologia única de avaliação de resultados.

A Discovery é pioneira no uso de Inteligência Artificial para a melhoria de empresas, com aplicações e pesquisas desenvolvidas desde a década de 1990.

