

LIFT *papers*

REVISTA do
LABORATÓRIO
de INOVAÇÕES
FINANCEIRAS e
TECNOLOGICAS

1ª EDIÇÃO

LIFT Papers

Revista do Laboratório de Inovações Financeiras
e Tecnológicas

Volume 1 • Número 1 • Março 2019

Editor-Chefe da Revista

André Henrique de Siqueira

Editor Adjunto da Revista

Aristides Andrade Cavalcante Neto
Rodrigo de Azevedo Henriques

Corpo Editorial da Revista

Marcus Vinicius Cursino Suares
Rafael Sarres de Almeida
Jose Deodoro de Oliveira Filho
Ricardo Fernandes Paixão

Ficha catalográfica elaborada pela Biblioteca do Banco
Central do Brasil

LIFT Papers / Banco Central do Brasil. Vol. 1, n. 1,
(março 2019). Brasília: Banco Central do Brasil, 2019.

Semestral

Disponível em:

https://www.liftlab.com.br/docs/lift_Red.pdf.

ISSN

1. Inovação Tecnológica – Brasil. 2. Sistema Financeiro –
Brasil. 3. Crédito. I. Banco Central do Brasil.

CDU 336.7:004.738:5

Presidente do Banco Central do Brasil

Roberto Campos Neto

Presidente da Fenasbac

Paulo Stein

Comitê Executivo LIFT 2018

Adriana Teixeira de Toledo
Aloisio Tupinambá Gomes Neto
André Henrique de Siqueira - Coordenação
Aristides Andrade Cavalcante Neto – Coordenação
Breno Santana Lobo
Helio Fernando Siqueira Celidonio
Jose Deodoro de Oliveira Filho
Lucila Cepeda Simão Ferreira – Coordenação
Marcos de Oliveira Machado
Marcus Vinicius Cursino Suares
Paulo Ricardo da Rosa
Rafael Sarres de Almeida
Reinaldo Lívio Wielewski
Rodrigo de Azevedo Henriques – Coordenação
Tatyana de Pinho Falcão – Coordenação

Representantes dos Parceiros de Tecnologia

AWS Rodrigo Akira Hirooka

Leandro Bennaton

IBM Fabio Luis Marras

Vicente Ranieri

Leonardo Guaraldi Couto

ORACLE Gabriel Maranhão

Rodrigo Solon

MICROSOFT Ronan Damasco

João Paulo Fernandes

Cristiano Gomes



O impacto da evolução tecnológica sobre o cotidiano também alcança a economia. As possibilidades que o mundo digital propicia não podem passar despercebidas a todos nós dedicados ao sistema financeiro do futuro. Para desenvolver esse potencial e conectar problemas com soluções, o Banco Central criou o LIFT, o Laboratório de Inovações Financeiras e Tecnológicas.

Com foco no sistema financeiro, o LIFT eleva mentes criativas do patamar da ideia à concretude. Empreendedores, pesquisadores e inventores que vislumbram novos caminhos tecnológico-financeiros encontram no LIFT a chance de lapidar suas ideias.

No laboratório, a inventividade do participante completa um tripé colaborativo com a experiência do BCB e o conhecimento de provedores de tecnologia. O resultado não poderia ser outro: transformar projetos em soluções e soluções em ganhos para a sociedade.

Esta revista compila os resultados da primeira edição do LIFT. Alguns projetos estão em fase avançada de implementação, outros vêm à tona aos poucos. O leitor especializado poderá conhecê-los mais a fundo enquanto o leitor meramente curioso terá uma noção do quanto suas finanças podem mudar, para melhor. Adicionalmente, a revista apresenta algumas reflexões sobre tendências na área.

Boa leitura.

Roberto Campos Neto

6

Instant Spyglass

O *Instant Spyglass* será uma plataforma para detecção de desvios de atendimento por meio da análise dos registros de contatos entre os clientes e as instituições financeiras. Os contatos analisados pelo *Instant Spyglass* serão multimídia, isto é, a plataforma será capaz de processar voz, *chat*, trilhas de auditoria e demais logs de sistemas para construir e aprimorar seu funcionamento. O sistema utilizará reconhecimento de voz e aprendizado de máquina como base para atingir seus objetivos. A transcrição de voz em texto e a análise dos diálogos usando inteligência artificial comporão um modelo disruptivo de detecção de atendimentos com qualidade diferente da esperada pela instituição.

..... Introdução

O *Instant Spyglass* é a proposta da *Instant Solutions* em sua participação no Laboratório de Inovações Financeiras e Tecnológicas (LIFT), programa inédito de apoio à inovação do Banco Central do Brasil (BCB), que conta com apoio da Amazon, IBM, Microsoft e Oracle.

Valendo-se de poderosas ferramentas de inteligência artificial, o *Instant Spyglass* pretende aprimorar a detecção de desvios de atendimento por meio da análise dos registros de contatos entre os clientes e as operadoras de centrais de atendimento, especialmente as instituições financeiras.

Este documento, baseado no modelo de trabalho acadêmico abnTeX2 (2013), propõe-se a descrever o projeto de desenvolvimento do *Instant Spyglass* do ponto de vista técnico, com ênfase em suas características inovadoras e aplicabilidade para o Sistema Financeiro Nacional (SFN), e segue a seguinte estrutura: esta Introdução estabelece do que se trata o projeto, em linhas gerais, e apresenta uma breve descrição de cada seção do documento; a seção **Objetivos** define os objetivos do projeto; na seção **Fundamentação Teórica**, encontram-se a enumeração e a descrição das referências básicas utilizadas para o projeto; a seção **Visão Geral** descreve a declaração de visão do projeto em questão; a seção **Características Inovadoras** descreve

“O *Instant Spyglass* será uma plataforma para detecção de desvios de atendimento por meio da análise dos registros de contatos entre os clientes e as instituições financeiras.”

os detalhes das características de inovação do projeto; essas mesmas características são contextualizadas na seção **Contribuição** para o SFN; a seção **Restrições** discute fatores que possam restringir ou impedir a aplicação do projeto no SFN, sejam de ordem regulamentar ou de ordem prática; e, por fim, a seção **Conclusão** sumariza o conteúdo do documento.

Objetivos.....

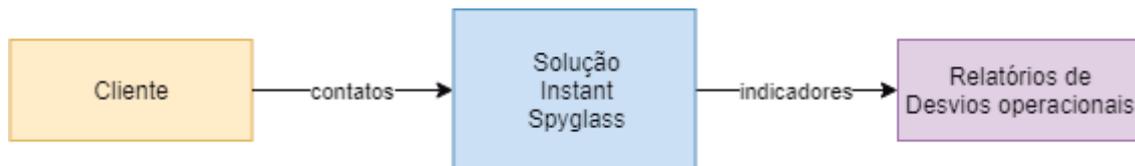
O crescente desenvolvimento tecnológico das centrais de atendimento habilita a produção de quantidades de dados cada vez maiores, com potencial para extração de inúmeras informações relevantes para o negócio. Os indicadores baseados na quantidade e na duração dos eventos de atendimento, bem como o conteúdo da conversa entre o cliente e a instituição, resguardado o devido direito à privacidade, são exemplos de importantes fontes de informação.

No caso de análise de conteúdo dos contatos, quer seja motivada por auditoria, qualidade ou desempenho, o monitoramento é realizado por profissionais treinados, que selecionam os contatos usando critérios empíricos. Considerando a grande quantidade de contatos e o processo quase todo manual, a escalabilidade fica prejudicada. Geralmente, nem todos os contatos relevantes são avaliados, e ações que poderiam ser proativas acabam sendo reativas, ocasionando demora e insatisfação e empurrando os índices de qualidade para abaixo do esperado.

O *Instant Spyglass* pretende mudar esse cenário, permitindo que os monitores atuem num conjunto de contatos pré-selecionados, com conteúdo relevante à

análise que se pretende realizar. Com o *Instant Spyglass*, a amostragem praticamente aleatória do processo atual é substituída por uma amostragem valorada de acordo com critérios predefinidos, buscando casos de desvios operacionais.

Figura 1: Visão geral da solução



O objetivo final é aumentar a eficácia da análise e reduzir o tempo de reação da operação diante de eventos específicos, tais como a insatisfação do cliente perante o atendimento ou a ocorrência de uma conversa suspeita. A consequência esperada é o reflexo positivo nos indicadores de qualidade da central de atendimento.

- Sistemas Baseados em Conhecimento (*knowledge-based systems*);
- Sistemas de Aprendizado de Máquina (*machine learning systems*).

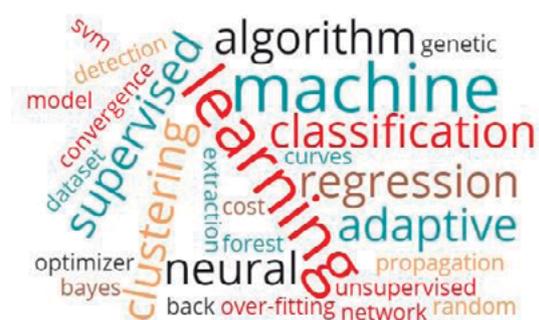
Sistemas Baseados em Conhecimento efetuam inferências lógicas a partir de uma base de conhecimento construída com o auxílio de especialistas humanos. Quando restritos a um domínio específico de conhecimento (medicina, direito etc.), são denominados Sistemas Especialistas.

Fundamentação Teórica

Visão geral

Chamamos de Inteligência Artificial (IA) a inteligência observada em uma máquina (mais especificamente em um algoritmo computacional), em oposição à inteligência natural observada em seres humanos [1]. É a capacidade de uma máquina desempenhar funções cognitivas geralmente associadas a uma mente humana, tais como aprender, compreender e se comunicar em linguagem natural, identificar padrões e resolver problemas complexos.

Os sistemas de Inteligência Artificial podem ser divididos em duas grandes famílias [2]:



Sistemas de Aprendizado de Máquina, por sua vez, aprendem exclusivamente a partir da observação de eventos, sem regras pré-definidas, identificando padrões e aprimorando seu próprio desempenho ao longo do tempo. Esse sistemas têm sido

utilizados com surpreendente sucesso nos últimos anos em diversas áreas de aplicações tais como:

- Sistemas de Recomendação (filmes, músicas, livros, restaurantes, produtos etc.);
- Transporte (indicação de rota, previsão de tráfego, aplicativos de transporte etc.);
- Previsão de Séries Temporais (clima, demanda de energia, preços etc.);
- *Marketing* (segmentação de clientes, perfil de consumidor etc.);
- Segurança (detecção de fraudes, invasões etc.);
- Visão Computacional (reconhecimento de rostos, objetos, veículos autônomos etc.);
- Medicina (diagnóstico por imagem, prognóstico, prescrição de tratamento etc.);
- Processamento de Linguagem Natural.

Especificamente na área do processamento de linguagem natural, as principais aplicações de aprendizado de máquina têm sido:

- conversão voz/texto e texto/voz;
- compreensão de linguagem natural;
- tradução automática entre idiomas;
- conversão de dados em texto;
- classificação de textos;
- análise de sentimento;
- reconhecimento óptico de caracteres;
- reconhecimento de caligrafia humana;
- ferramenta inteligente de pesquisa *on-line*;
- assistentes pessoais virtuais;
- atendimento *on-line* em linguagem natural (*chatbots*).



Técnica

Os métodos de aprendizado de máquina são tipicamente classificados em três categorias amplas, de acordo com a natureza do “sinal” ou “*feedback*” disponível para o sistema de aprendizado. Essas categorias são [1]:

- aprendizado supervisionado;
- aprendizado não supervisionado;
- aprendizado por reforço.

No aprendizado de máquina supervisionado, um conjunto de dados é fornecido inicialmente ao sistema de aprendizado, contendo exemplos das entradas e saídas desejadas. O objetivo do sistema é aprender uma regra geral que mapeia as entradas para as saídas.

No aprendizado de máquina não supervisionado, nenhum tipo de exemplo é dado ao sistema de aprendizado, deixando-o sozinho para encontrar estrutura nas entradas fornecidas.

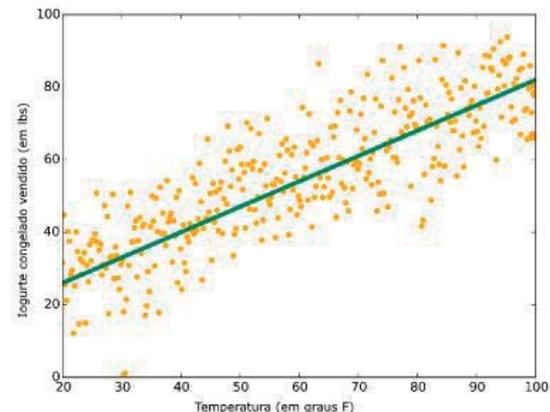
No aprendizado de máquina por reforço, o sistema interage com um ambiente dinâmico para desempenhar determinada tarefa (por exemplo, dirigir um veículo ou jogar um jogo). Durante a interação do sistema com o ambiente, ele recebe *feedback* positivo ou negativo, para que aprenda se suas decisões são boas ou ruins para o objetivo que se quer atingir.

No *Instant Spyglass*, usaremos o aprendizado de máquina supervisionado. Problemas que podem ser resolvidos por esse método podem ser classificados em três tipos distintos, de acordo com a natureza da saída desejada:

- regressão;
- classificação;
- detecção de anomalias.

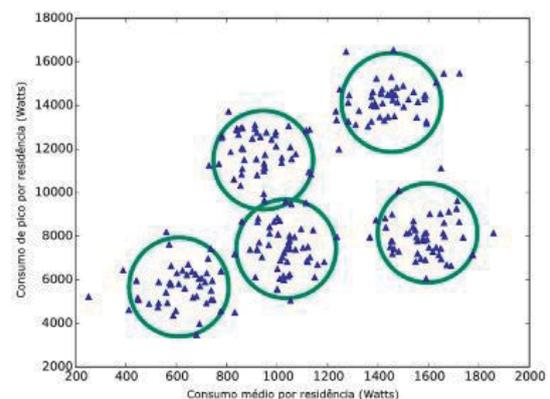
Na regressão, tentamos prever os resultados em uma saída contínua, o que significa que estamos tentando mapear variáveis de entrada para uma função contínua.

Exemplo de regressão



Na classificação, tentamos prever os resultados em uma saída discreta, ou seja, tentamos mapear variáveis de entrada em categorias distintas. Se houver apenas duas opções de categoria, a classificação é binomial ou de duas classes. Se houver mais de duas opções de categoria, a classificação é multiclasse.

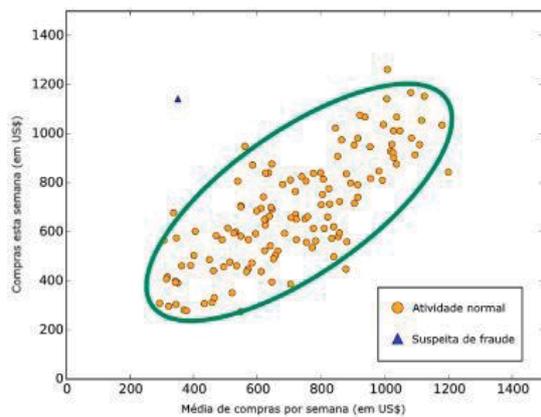
Exemplo de classificação multiclasse



Na detecção de anomalias, o objetivo é identificar os dados que são incomuns. Na detecção de fraudes, por exemplo, quaisquer padrões incomuns de gasto em cartão de

crédito são suspeitos. As variações possíveis são tão numerosas que não é viável aprender como seria uma atividade fraudulenta. A abordagem que usa detecção de anomalias é simplesmente aprender como é uma atividade normal (usando transações não fraudulentas históricas) e identificar tudo que seja significativamente diferente.

Exemplo de detecção de anomalias



Processo

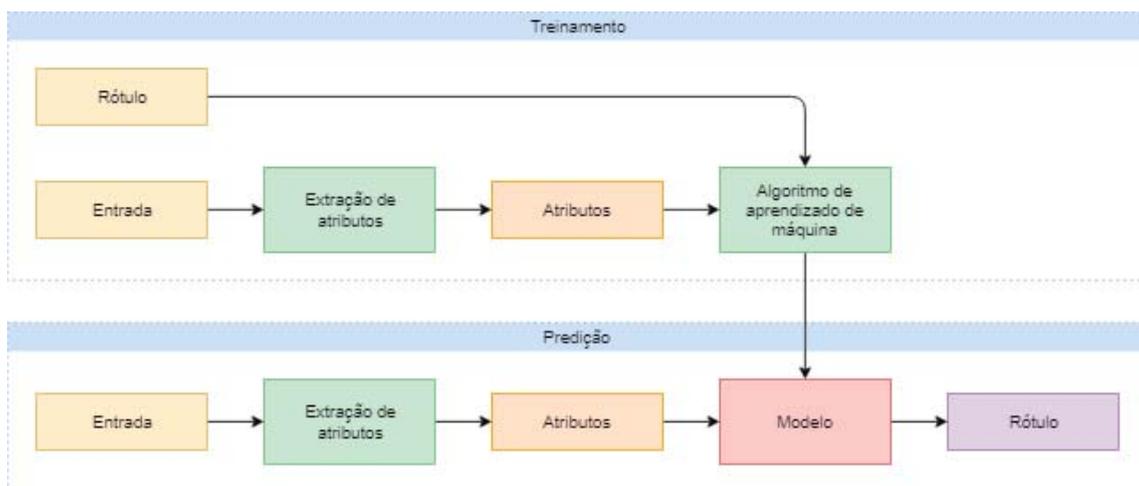
O aprendizado de máquina supervisionado consiste de duas etapas:

- treinamento;
- predição.

Na etapa de treinamento, os dados são apresentados ao sistema de aprendizado na forma de um conjunto de atributos acompanhado pelo valor de saída correspondente ao conjunto de atributos fornecido. O valor de saída fornecido no treinamento é chamado de “rótulo”, e os dados fornecidos no treinamento são chamados de “dados rotulados”.

Na etapa de predição, dado um novo conjunto de atributos, nunca antes visto e não rotulado, o sistema de aprendizado deve estimar o valor de saída correspondente a esse conjunto da forma mais acurada possível, usando as informações fornecidas na etapa de treinamento como modelo.

Etapas de treinamento e predição



Um sistema de aprendizado de máquina pode ter seu modelo continuamente aprimorado, sem intervenção humana, durante a operação. Por meio da utilização de dados de produção rotulados para treinamento contínuo, o modelo se autoaperfeiçoará e, com o passar do tempo, poderá fornecer respostas cada vez mais próximas da realidade.

Sistema especialista

É importante ressaltar a diferença entre o aprendizado de máquina e um sistema especialista.

Um sistema especialista utiliza um conjunto de regras fixas, estabelecidas *a priori*, que correlacionam os atributos ao alvo. Por exemplo, identificar a frequência de ocorrência de determinadas expressões compostas por uma ou mais palavras (atributos), para determinar o grau de utilização de linguagem grosseira (alvo).

No caso do aprendizado de máquina, entretanto, nenhuma regra é estabelecida *a priori*. A seleção dos atributos, bem como as regras que relacionam os atributos selecionados ao alvo, são inferidas automaticamente a partir dos dados disponíveis para treinamento [3].

Aplicabilidade

O *Instant Spyglass* utilizará tanto aprendizado de máquina quanto um sistema especialista, dependendo do tipo de avaliação que será realizada.

Na etapa de treinamento do aprendizado de máquina, o conteúdo da conversa será apresentado ao sistema de aprendizado na forma de um conjunto de atributos, acompanhado por um rótulo que indica a pontuação da conversa na

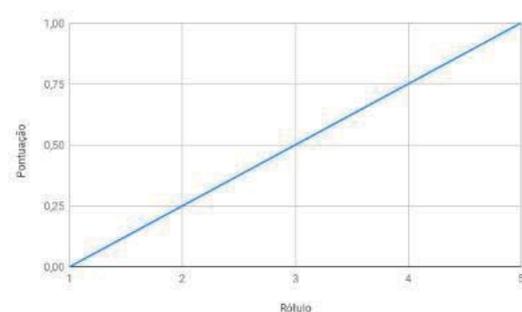
métrica desejada, por exemplo, satisfação do cliente.

Os atributos extraídos do conteúdo da conversa corresponderão às contagens de ocorrências de expressões compostas por uma, duas ou mais palavras consecutivas (n-gramas), além de outras informações mais complexas derivadas do texto.

Na etapa de predição, dado o conjunto de atributos do conteúdo de uma nova conversa, nunca antes vista e não rotulada, o sistema de aprendizado estimará um valor de saída, que chamaremos de pontuação, para a métrica na qual foi treinado. A pontuação será expressa de forma padronizada em uma escala numérica fracionária no intervalo entre 0 e 1, podendo ser entendida como uma medida abstrata da variável a ser estimada.

Se o sistema for treinado com rótulos quantitativos, o valor da pontuação tenderá a ser proporcional à escala utilizada no seu treinamento. Por exemplo, se a variável a ser estimada for a satisfação do cliente e o sistema for treinado com rótulos informando um número de um a cinco, atribuído ao atendimento pelo cliente em uma pesquisa de satisfação, a pontuação estimada será proporcional (na escala de 0 a 1) à escala utilizada no treinamento (na escala de 1 a 5).

Pontuação proporcional ao rótulo quantitativo



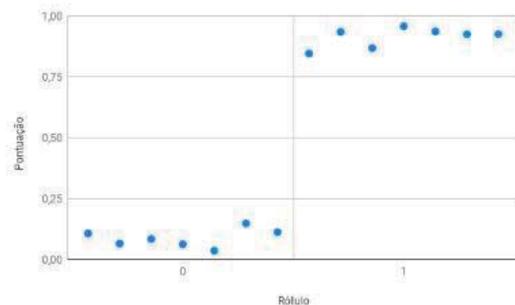
Cabe ressaltar que o grau de satisfação do cliente está sendo considerado como



uma medida de valor contínuo, e não como um conjunto de categorias discretas (insatisfeito, indiferente e satisfeito, por exemplo). Sendo assim, observa-se que não há sentido em interpretar essa medida em termos probabilísticos.

No caso de um sistema treinado com rótulos categóricos – por exemplo, valor zero para diálogo com intenção legítima e valor um para diálogo com intenção de fraude –, a pontuação tenderá a ser próxima de zero para diálogos que se assemelham a um diálogo com intenção legítima e próxima de um para diálogos que se assemelham a um diálogo com intenção de fraude.

Pontuação correspondente a um critério categórico



Em termos probabilísticos, pode-se afirmar que a probabilidade estimada de haver intenção de fraude será tanto maior quanto maior for a pontuação atribuída ao diálogo pelo sistema. Entretanto, isso não significa que a pontuação corresponde à probabilidade de haver intenção de fraude, pois trata-se apenas de um critério de proximidade relativa entre as características do diálogo a ser categorizado e as características observadas durante o treinamento em diálogos com intenção legítima e em diálogos com intenção de fraude.

.....Visão Geral

Arquitetura

O *Instant Voice* é uma plataforma de comunicação e de atendimento a clientes, desenvolvida pela *Instant Solutions* Tecnologia e Informática, com recursos avançados de telefonia: organização de ramais e filas de espera, gravação de tela e voz, salas de conferência, unificação de mensagens de *e-mail*, voz e SMS para um só meio de recebimento, geração de relatórios *on-line* ou por *e-mail* e diversas outras características.

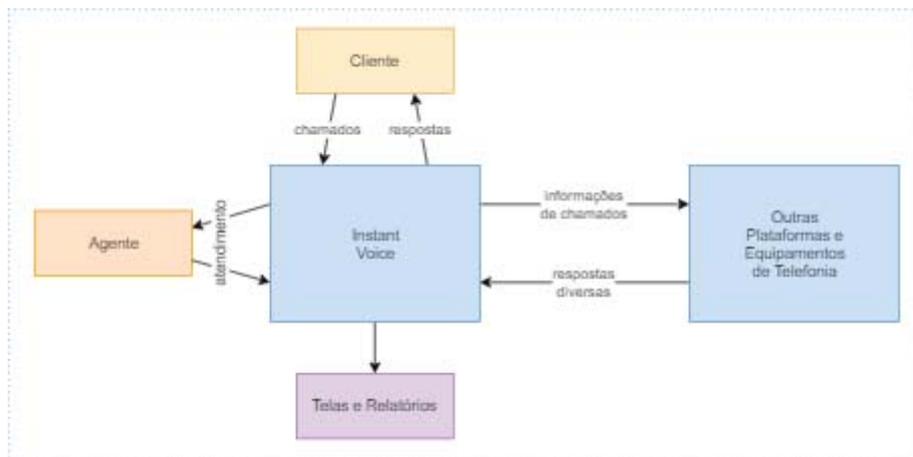
O *Instant Spyglass* será uma plataforma para detecção de desvios de atendimento

por meio da análise dos registros de contatos entre os clientes e as instituições financeiras. A solução está sendo projetada usando ferramentas de mercado e padrões de API abertos, visando futura integração com outros provedores de registros de contatos realizados.

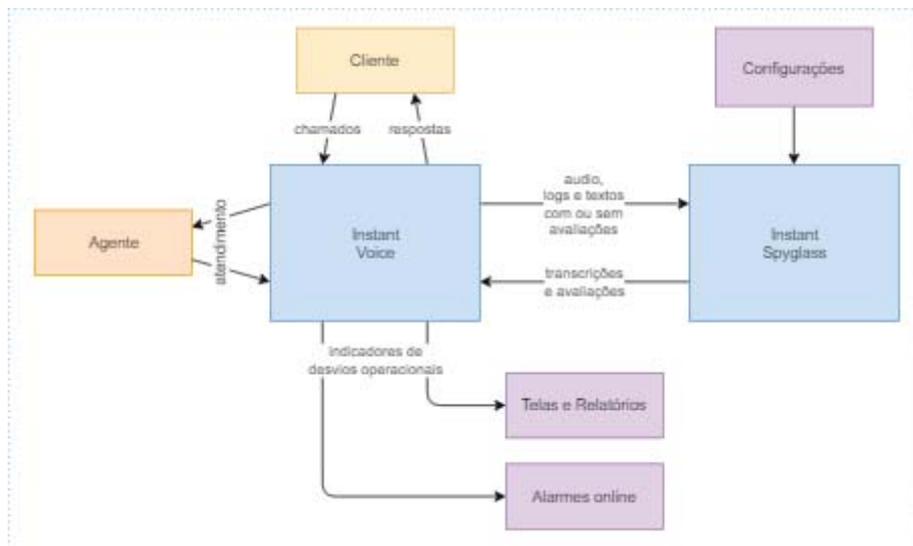
O *Instant Spyglass* usará IA para analisar os registros de contatos realizados por canais de voz e de texto. Se a entrada vier de um canal de voz, a conversa será convertida de voz em texto. Em seguida, o texto correspondente ao contato, seja original ou transcrito, será submetido a um motor de avaliação com métricas predefinidas.

Na conversão de voz para texto, as gravações das conversas entre atendentes e

Instant Voice – Visão geral



Instant Voice e Instant Spyglass – Visão geral



clientes serão transcritas automaticamente por ferramenta de mercado, que converterá os arquivos de áudio em arquivos de texto, utilizando modelo de aprendizado supervisionado pré-treinado para conversação no idioma português brasileiro.

O motor de avaliação será capaz de realizar os seguintes tipos de análise:

- análise de padrão de linguagem;
- análise de sentimento;
- detecção de anomalias.

A análise de padrão de linguagem usará um sistema especialista baseado na comparação de histogramas de expressões presentes no texto com um dicionário de expressões pré-cadastradas. Usaremos essa análise para identificar linguagem grosseira. No futuro, poderão ser acrescentados outros critérios, por meio da criação de dicionários com as expressões e os pesos desejados.

A análise de sentimento usará tecnologia de aprendizado de máquina para aprender a reconhecer textos que correspondem aos critérios desejados, por meio de um modelo (conjunto de regras) inferido automaticamente a partir dos dados durante o processo de treinamento. Usaremos essa

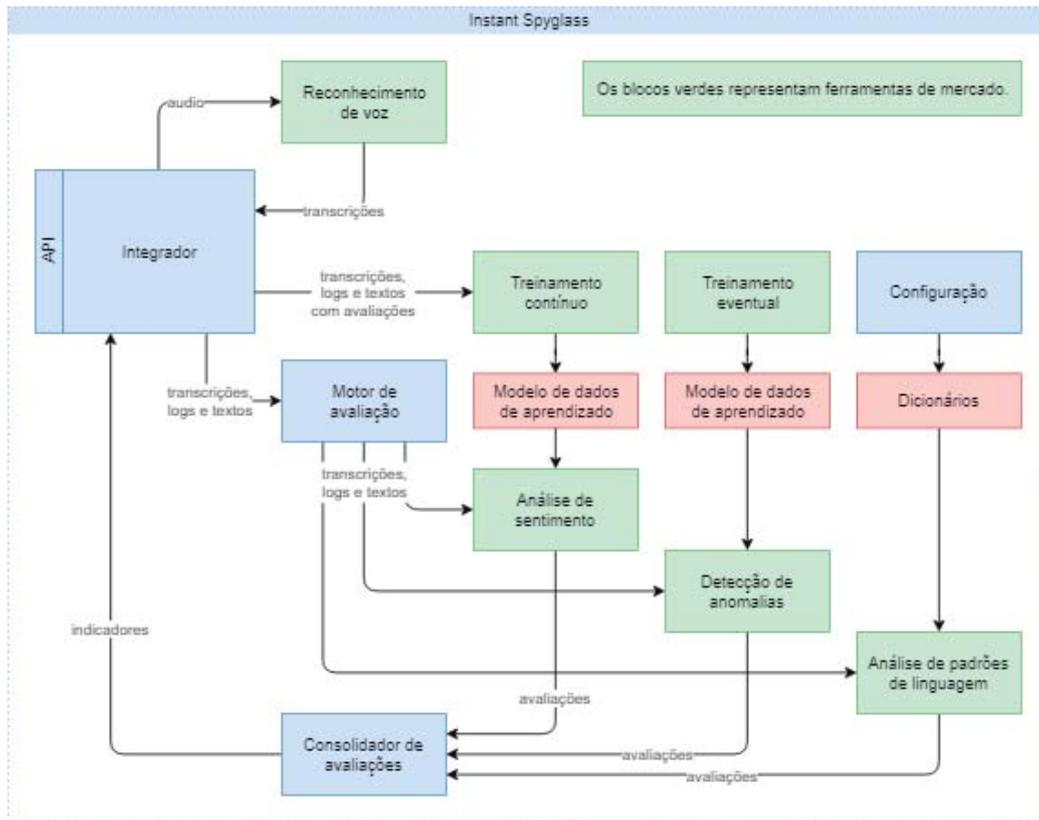
análise para interpretar a satisfação do cliente com o contato realizado. Para que os resultados sejam satisfatórios, textos ou áudios de contatos previamente avaliados devem ser submetidos à plataforma para treinamento do modelo.

Considerando que é possível solicitar que o usuário avalie o atendimento, o *Instant Spyglass* suportará uma tecnologia de treinamento contínuo para a análise de sentimento, permitindo que a plataforma ganhe experiência na medida em que vá sendo treinada.

A detecção de anomalias também usará tecnologia de aprendizado de máquina para aprender a reconhecer textos que correspondem aos critérios desejados, mas os algoritmos e modelos são diferentes daqueles usados na análise de sentimento. Usaremos a detecção de anomalias para identificar suspeita de fraude nos contatos realizados. Nesse caso, não será usado o treinamento contínuo, pois dificilmente haveria meios para realização de uma pré-avaliação contínua, de forma a suportar esse tipo de abordagem.

O diagrama a seguir ilustra a arquitetura dos principais módulos da solução.

Instant Spyglass – Visão interna



Na análise de sentimento e na detecção de anomalias, o conteúdo de cada conversa será analisado pelo módulo de predição com um modelo personalizado de aprendizado supervisionado, treinado com diálogos reais da central de atendimento. A pontuação retornada pela análise será expressa em uma escala numérica fracionária no intervalo entre 0 e 1.

A construção de alertas, séries históricas e relatórios operacionais, bem como a integração com ferramentas de inteligência de negócio, serão feitas pelo *Instant Voice*, ou, quando for o caso, pela plataforma de comunicação integrada ao *Instant Spyglass*.

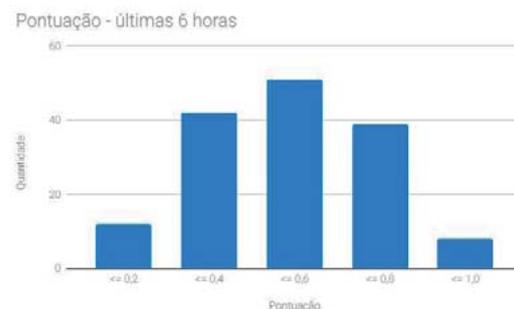
Casos de Uso

A pontuação dos contatos retornada pelo *Instant Spyglass* será usada pelo *Instant Voice* das seguintes formas:

- geração de alertas imediatos caso um contato seja avaliado com uma pontuação abaixo ou acima de limites preestabelecidos;
- geração de relatórios com os contatos de um período ordenados de acordo com a respectiva pontuação.

As figuras a seguir ilustram a concepção de alguns relatórios que serão gerados.

Exemplo de gráfico operacional

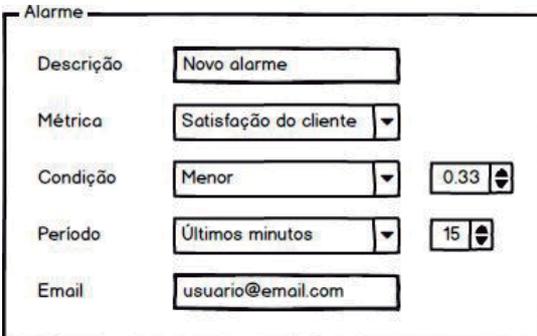


Exemplo de relatório detalhado

Data	Hora	Tipo	Origem	Destino	Operador	Duração	Pontuação
04/09/2018	14:35:20	Entrante	9876-1234	6109	1232	00:08:32	0.12
04/09/2018	15:18:42	Entrante	3545-1234	6109	1232	00:05:45	0.32
04/09/2018	15:01:00	Sainte	6120	98188-1233	1216	00:12:44	0.43
04/09/2018	14:39:03	Entrante	85766-1234	6118	1204	00:05:16	0.53
04/09/2018	15:12:17	Entrante	2238-1234	6132	1231	00:04:35	0.61
04/09/2018	14:46:54	Sainte	6124	97787-6543	1214	00:07:44	0.64
04/09/2018	15:08:21	Sainte	6124	94412-3456	1214	00:09:23	0.83

Configurar alarmes *on-line*

O usuário define o alarme desejado. Cada alarme possui um código, uma descrição, uma condição, uma pontuação limite, um período e um endereço de *e-mail* do destinatário. O intervalo da pontuação é entre 0 e 1, inclusive. A condição determina se o limite é um valor mínimo ou máximo para a pontuação dos contatos.



Alarme

Descrição: Novo alarme

Métrica: Satisfação do cliente

Condição: Menor 0.33

Período: Últimos minutos 15

Email: usuario@email.com

Consultar alarmes disparados

Quando um alarme é disparado, um *e-mail* é enviado ao destinatário. A tela de

consulta de alarmes disparados é útil caso vários alarmes sejam disparados num curto espaço de tempo ou para consulta histórica do disparo de alarmes.

Consultar pontuação de contatos

Todos os contatos são pontuados com relação aos critérios predefinidos. Na solução submetida ao LIFT, será usado o critério de satisfação do cliente. A consulta mostrará os contatos ocorridos num período especificado pelo usuário, ordenados pela pontuação. Assim, será possível identificar os contatos com maior probabilidade de terem gerado insatisfação do cliente nas últimas quatro horas, por exemplo. Esses contatos podem ser analisados pela equipe de qualidade da central de atendimento a fim de identificar os problemas e providenciar a solução.



ID	Nome	Descrição	Horário	
2	Alarme 2	Linguagem grosseira maior que 0.95	04/09/2018 16:45:12	Consultar Limpar
3	Alarme 3	Satisfação menor que 0.15 em 5 minutos	04/09/2018 17:11:40	Consultar Limpar

Data	Hora	Tipo	Origem	Destino	Operador	Duração	Avaliação	Consultar
04/09/2018	14:35:20	VOZ-Entrante	9876-1234	6109	1232	00:08:32	0.12	Texto Audio
04/09/2018	15:18:42	SMS-Entrante	3545-1234	6109	1232	00:05:45	0.32	Texto
04/09/2018	15:01:00	VOZ-Sainte	6120	98188-1233	1216	00:12:44	0.43	Texto Audio
04/09/2018	14:39:03	VOZ-Entrante	85766-1234	6118	1204	00:05:16	0.53	Texto Audio
04/09/2018	15:12:17	BOT-Entrante	2238-1234	6132	1231	00:04:35	0.61	Texto
04/09/2018	14:46:54	VOZ-Sainte	6124	97787-6543	1214	00:07:44	0.64	Texto Audio
04/09/2018	15:08:21	VOZ-Sainte	6124	94412-3456	1214	00:09:23	0.83	Texto Audio

Pesquisa de satisfação

O motor de inteligência artificial necessita de treinamento para aprender a classificar os contatos. O treinamento proposto na solução é realizado a partir de contatos nos quais o cliente tenha respondido uma pesquisa de satisfação. Na impossibilidade de o cliente responder a uma pesquisa de satisfação, a informação equivalente deve ser fornecida ao sistema, pelo menos para uma parte dos contatos, para que o treinamento possa ser realizado.

Métricas

O *Instant Spyglass* terá as seguintes métricas disponíveis:

- SAC Satisfação do cliente;
- LGC Linguagem grosseira do cliente;
- SFC Suspeita de fraude do cliente;
- LGA Linguagem grosseira do agente;
- SFA Suspeita de fraude do agente.

Escopo do protótipo

O protótipo construído apresenta grande parte das características definidas para o projeto, mas os recursos são limitados, e optamos por deixar algumas características para o futuro.

A documentação técnica do protótipo pode ser acessada em: <https://spyglass-api-app-dev.azurewebsites.net/docs>.

Características do protótipo

As características a seguir estão sendo implementadas no protótipo:

- Integração com o *Instant Voice* por meio de API Swagger.
 - » O uso do padrão Swagger permite que outros fornecedores de PABX digital possam integrar seus produtos facilmente ao *Instant Spyglass*.
- Transcrição de mensagens de voz.
 - » A transcrição de mensagens de voz está implementada preliminarmente por meio do serviço *Speech to Text*, disponível na plataforma Azure da Microsoft, pois ainda estamos investigando alternativas, inclusive na área acadêmica nacional [4], para melhorar o desempenho.
- Análise de sentimento, usada na interpretação da satisfação do cliente.
 - » A análise de sentimento está implementada por meio da

ferramenta Vowpal Wabbit da Microsoft, que é disponibilizada de forma nativa no Azure ML Studio.

- Relatórios de contatos com dados detalhados, inclusive as pontuações retornadas pelas avaliações do *Instant Spyglass*.
 - » Relatórios em modo texto e gráfico com dados detalhados, filtros, exportação etc. implementados na plataforma Instant Voice.

As características a seguir serão implementadas futuramente.

- Detecção de anomalias, usada na identificação de desvio de comportamento e suspeita de fraude.
 - » A detecção de anomalias será implementada por meio da ferramenta ainda a ser definida.
- Operação *on-line*. Por enquanto, a transcrição dos diálogos, a avaliação dos textos e a geração de pontuação serão realizadas por processo *batch*, que rodará à noite na plataforma *Instant Voice*, ou seja, no protótipo não teremos alertas *on-line* funcionais e os relatórios exibirão dados de D-1.
 - » Tecnicamente isso não é uma limitação da plataforma *Instant Spyglass*, pois ela é capaz de realizar avaliações em qualquer horário, mediante API.
- Uso de *blockchain* para tornar informações e trilha de auditoria indelévels.
- Pesquisa por palavra-chave e expressões nos textos dos contatos.

Prova de conceito

O módulo de aprendizado de máquina do *Instant Spyglass* é responsável por analisar textos transcritos de diálogos entre clientes e atendentes em canais de atendimento, utilizando uma técnica de aprendizado supervisionado denominada “análise de sentimento”.

Para cada texto analisado, o nível de satisfação do cliente é estimado por um valor fracionário na faixa de 0.0 a 1.0, sendo 0.0 correspondente a extremamente insatisfeito e 1.0 correspondente a extremamente satisfeito.

Os textos avaliados em um determinado período de tempo (por exemplo, um dia) podem ser ordenados em ordem decrescente de satisfação do cliente, possibilitando assim selecionar, para análise por parte da gestão da central de atendimento, os diálogos que atingiram os níveis mais altos de satisfação, bem como os que atingiram os níveis mais baixos.

O treinamento do sistema de aprendizado é feito de modo supervisionado, fornecendo-se ao sistema um conjunto de exemplos de textos transcritos do atendimento, acompanhados de uma medida numérica do nível de satisfação alcançado, atribuída pelo próprio cliente ou por colaboradores da central de atendimento incumbidos de avaliar o atendimento.

O modelo de aprendizado utilizado é *on-line*, ou seja, o modelo é continuamente aprimorado a cada vez que recebe como exemplo de treinamento um novo texto rotulado com a respectiva medida de satisfação alcançada. Assim, com o passar do tempo, na medida em que vai sendo treinado com mais e mais exemplos rotulados, o sistema tende a produzir estimativas cada vez melhores para novos textos não rotulados que venha a receber para estimar o grau de satisfação.

O pacote de *software* de aprendizado de máquina utilizado no protótipo foi o Vowpal Wabbit da Microsoft, que é disponibilizado de forma nativa no Azure ML Studio.

Para ajustar e fazer uma avaliação preliminar do desempenho do modelo preditivo construído no Vowpal Wabbit, foi necessário realizar experimentos de análise de sentimento com dados reais. Devido à indisponibilidade de uma base de dados que contivesse exemplos de diálogos reais de uma central de atendimento rotulados com medida de satisfação, foi necessário utilizar uma base de dados alternativa para validar o protótipo.

Para representar com a melhor fidelidade possível um teste com base de dados real de central de atendimento, fazia-se necessária uma base de dados pública que contivesse uma grande quantidade de textos, acompanhados de suas respectivas medidas de intensidade de sentimento (negativo ou positivo).

Como o algoritmo do Vowpal Wabbit se baseia exclusivamente no aprendizado estatístico dos padrões encontrados no conjunto de treinamento, sem se basear em nenhum conhecimento prévio de linguística, pode-se supor que a capacidade de aprendizado tenha pouca dependência do idioma.

De acordo com essas premissas, selecionamos como escopo de teste uma base de dados pública denominada *Large Movie Review Dataset*, composta por 50.000

comentários de pessoas a respeito de filmes no *website* IMDB, sendo 25.000 comentários com sentimento positivo (notas de 7 a 10) e 25.000 comentários com sentimento negativo (notas de 1 a 4).

Na prova de conceito, simulamos a evolução do desempenho do modelo preditivo com número crescente de amostras por meio de dois experimentos. O desempenho do modelo preditivo foi apurado em termos da taxa de acerto obtida na estimativa de sentimento negativo ou positivo em um conjunto de teste composto por 10.000 amostras não rotuladas e não utilizadas no treinamento.

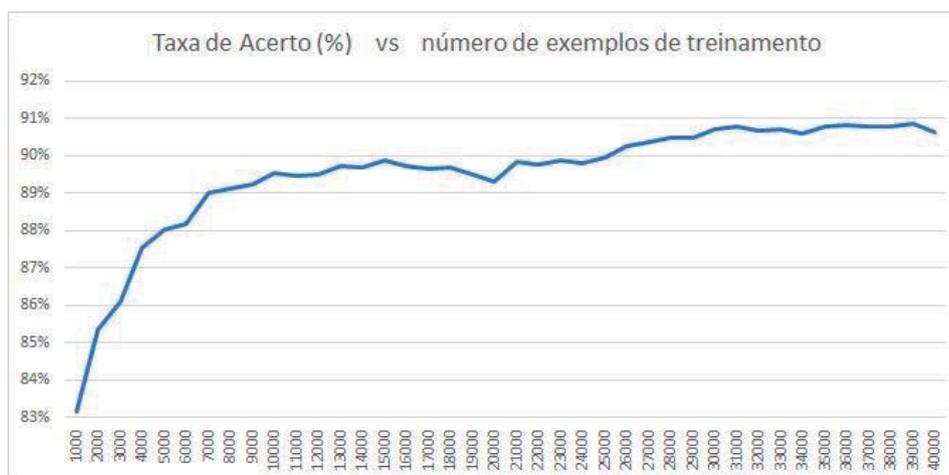
No primeiro experimento, foi verificada a evolução da taxa de acerto apresentando 25 amostras de treinamento a cada etapa, até acumular um total de 1.000 amostras de treinamento.

No segundo experimento, foi verificada a evolução da taxa de acerto, apresentando 1.000 amostras de treinamento a cada etapa, até acumular um total de 40.000 amostras de treinamento.

Os resultados obtidos até o acúmulo de 1.000 amostras de treinamento são exibidos no gráfico a seguir. A taxa de acerto do modelo preditivo inicia em 50% para o modelo não treinado (que fornece respostas aleatórias) e evolui gradualmente a cada novo conjunto de 25 amostras rotuladas observadas, atingindo 83,14% após 40 etapas de treinamento (1000 amostras rotuladas observadas).



O gráfico seguinte mostra a continuação da evolução da taxa de acerto na medida em que o modelo preditivo é treinado com mais e mais amostras rotuladas. A taxa de acerto continua aumentando gradualmente, em ritmo cada vez mais lento e, a partir de 30.000 amostras rotuladas observadas, parece estacionar na faixa de 90,6 a 90,9%.



Avaliamos que o resultado obtido foi bom e acreditamos que pode ser consideravelmente melhorado se forem investidos esforços adicionais na otimização do desempenho do modelo preditivo, uma vez que este possui um grande número de parâmetros ajustáveis que influem no seu desempenho.

Características Inovadoras

A inovação proposta pelo *Instant Spyglass* é o uso de inteligência artificial para avaliar, de forma ágil e confiável, os registros de contatos entre os clientes e as instituições financeiras. As avaliações poderão ser configuradas e contam com diversas métricas, que vão da indicação do uso de linguagem grosseira à identificação de suspeita de fraude.

As características que contribuem para esta inovação estão listadas a seguir.

- **Transcrição on-line** de diálogos de voz para texto.
 - » Os contatos realizados por meio de ligação telefônica e demais canais de voz poderão ser convertidos em texto poucos minutos após a ocorrência do contato, possibilitando diversos tipos de análise *on-line*.
 - » Pela parceria com os fornecedores de ferramentas, pretendemos criar modelos adaptados a negócios específicos, possibilitando transcrições de alta qualidade.
- Interpretação do grau de satisfação do cliente usando **análise de sentimento**.
 - » A análise de sentimento será realizada por um modelo de aprendizado de máquina

- supervisionado e especialista, que será continuamente treinado com dados fornecidas pelos clientes ou por agentes treinados para isso, em lugar de um modelo previamente treinado com dados genéricos originados por diferentes fontes.
- » O uso de técnicas de aprendizado contínuo fará com que a acurácia na estimativa da satisfação do cliente melhore gradativamente ao longo do tempo, à medida que o sistema for aumentando sua experiência por meio do treinamento.
- Identificação de **suspeita de fraude** usando algoritmos de detecção de anomalias.
 - » A identificação de suspeita de fraude será realizada por meio de algoritmos de aprendizado supervisionado, especializados em detecção de anomalias, previamente treinados para esta finalidade.
 - » Nesse caso, usaremos um modelo previamente treinado, pois dificilmente teremos avaliações nas quais basear o treinamento contínuo. Eventualmente, poderá haver manutenção para novo treinamento do modelo.
 - Utilização dos resultados das avaliações do *Instant Spyglass* de forma *on-line* ou integrada a outras **métricas de qualidade**.
 - » As pontuações geradas serão entradas para alertas *on-line* de situações sensíveis e também produzirão indicadores de qualidade para relatórios operacionais e de inteligência de negócio.
 - » Com base nos indicadores obtidos, poderão ser planejadas ações para melhorar a qualidade do atendimento, com impacto positivo na satisfação dos clientes e outros KPIs do negócio.
 - Foco no aproveitamento máximo do tempo e do **potencial do avaliador humano**, apresentando diretamente as amostras mais relevantes para revisão e tomada de decisão quanto a medidas preventivas e corretivas.
 - » Centrais de atendimento frequentemente monitoram os contatos para avaliar a qualidade do atendimento, geralmente de forma aleatória. Em épocas de auditoria, essa necessidade pode aumentar. A avaliação automática oferecida pelo *Instant Spyglass* permitirá que os avaliadores humanos analisem um conjunto de dados previamente selecionados, aumentando a produtividade e, espera-se, a efetividade.

Contribuição para o SFN

Sob a ótica dos temas da Agenda BC+, que tem como objetivo revisar questões estruturais do Banco Central e do Sistema Financeiro Nacional (SFN), gerando benefícios sustentáveis para a sociedade brasileira, o *Spyglass* contribui da seguinte forma:

- A identificação rápida de desvios de comportamento no atendimento proporciona maior proteção ao cidadão consumidor de produtos e de serviços financeiros (**mais cidadania financeira**).
- A análise dos indicadores de satisfação

do cliente e as decorrentes ações de qualidade realizadas pelas instituições financeiras melhoram a comunicação e a transparência entre as instituições financeiras e seus clientes (**mais cidadania financeira**), bem como aprimoram o relacionamento das instituições financeiras com clientes e usuários (**SFN mais eficiente**).

- O aumento da eficácia da análise, seja de satisfação do cliente ou de desvios de comportamento, potencializado pela redução do tempo de reação frente a eventos relevantes, tais como um cliente muito insatisfeito ou uma conversa suspeita, tem forte potencial para redução de custos operacionais, o que pode ser refletido, pelo menos em parte, no custo do crédito (**crédito mais barato**).

.....Restrições

O *Instant Spyglass* é uma solução que inclui diversas tecnologias, sendo a mais poderosa e promissora a inteligência artificial baseada em aprendizado de máquina. Para que os resultados sejam satisfatórios, essa tecnologia depende de um conjunto de dados – textos ou áudios de contatos – previamente avaliados, que precisa ser produzido ao longo do processo de implantação ou construído a partir de uma iniciativa conjunta das instituições financeiras.

O reconhecimento de voz atualmente é o componente mais sensível da solução. Apesar da disponibilidade de diversas ferramentas no mercado, ainda não temos uma solução definitiva, considerando os dados de teste disponíveis. Estamos investigando alternativas.

Sendo uma plataforma para avaliação dos registros de contatos entre os clientes e as operadoras de centrais de atendimento, em especial as instituições financeiras, o *Instant Spyglass* depende de outra solução para gerar esses registros de contatos, que pode ser um PABX digital, como o *Instant Voice*, uma plataforma de atendimento multicanal, como o *Instant Contact*, ou uma solução de terceiros.

Apesar de a arquitetura interna do *Instant Spyglass* permitir a adaptação para diversos fornecedores de ferramentas de reconhecimento de voz e aprendizado de máquina, o protótipo desenvolvido usa os serviços de inteligência artificial da Microsoft.

Conclusão.....

Nas centrais de atendimento, questões conceitualmente simples como “quais os contatos de hoje onde os clientes se mostraram mais insatisfeitos com atendimento” ou “quais os contatos de hoje onde temos indício de suspeita de fraude” demandam esforço significativo para serem respondidas, e mesmo assim com baixa eficácia, devido à dificuldade de se monitorar e avaliar todos os contatos realizados.

O *Instant Spyglass* pretende mudar esse cenário, permitindo que os monitores atuem num conjunto de contatos pré-selecionados, com conteúdo relevante à análise que se pretende realizar. Com o *Instant Spyglass*, a amostragem praticamente aleatória do processo atual é substituída por uma amostragem valorada de acordo com critérios pré-definidos, buscando casos com mais probabilidade de desvios operacionais.

O protótipo construído para o LIFT é limitado em suas funcionalidades, mas o desenho da arquitetura de *software* está completo, e os padrões de integração usados são modernos, abertos, enquanto os padrões de indústria facilitam a integração com as plataformas de gestão de contatos, tais como PABX digital, usadas pelas centrais de atendimento.

Em função da indisponibilidade de dados reais de contatos, realizamos uma prova de conceito com uma base de dados pública denominada *Large Movie Review Dataset*, composta por 50.000 comentários de pessoas a respeito de filmes no website IMDB.

O resultado obtido foi bom e pode ser consideravelmente melhorado se forem investidos esforços adicionais na otimização do desempenho do modelo preditivo. Acreditamos que esse novo passo deve ser planejado quando for possível repetir os testes realizados usando dados reais de diálogos entre cliente e atendente em contexto de central de atendimento, uma vez que o ajuste ótimo de parâmetros de algoritmos de aprendizado de máquina geralmente depende da natureza dos dados de treinamento utilizados.



Referências

RUSSEL, S. J.; NORVIG, P. **Artificial intelligence: a modern approach**. Upper Saddle River, New Jersey: Prentice Hall, 2009.

ABU-MOSTAFA, Y. S., MAGDON-ISMAIL, M. e LIN, H. **Learning from data**. AMLbook, 2012.

MARSLAND, S. **Machine learning – An algorithmic perspective**. CRC Press, 2015.

QUINTANILHA, I. M.; BISCAINHO, L. W. P. ; NETTO, S. L. **Towards an end-to-end speech recognizer for Portuguese using deep neural networks**. Anais do XXXV Simpósio Brasileiro de Telecomunicações e Processamento de Sinais, 2017.

