

Solução Multiagente para Otimização de Vendas e Gestão de Clientes em Plataforma de CRM

Lucas Bhering¹, Eduardo Ferreira¹

¹Centro Federal de Educação Tecnológica Celso Suckow da Fonseca (CEFET/RJ)
Campus Maria da Graça – Rio de Janeiro, RJ – Brasil

lucas.bhering@aluno.cefet-rj.br, eduardo.ferreira@cefet-rj.br

Abstract. *With the growing volume of data in CRM systems, manual qualification and monitoring tasks increasingly cause delays in the sales pipeline. This paper proposes a multi-agent architecture integrated with Salesforce CRM to automate and optimize four critical sales pipeline processes. In the traditional model, CRM data is often underutilized, and manual procedures create bottlenecks and inconsistencies that hinder funnel scalability. Our methodology presents the solution through comparing time metrics (process cycle reduction), the agent-generated scores and conversion probabilities.*

Resumo. *Com o crescente volume de dados nos sistemas de CRM, as tarefas manuais de qualificação e monitoramento causam atrasos cada vez maiores no pipeline de vendas. Este artigo propõe uma arquitetura multiagente integrada ao CRM Salesforce para automatizar e otimizar quatro processos críticos do pipeline de vendas, sendo eles a qualificação e avaliação de leads, saúde e priorização de contas, validação e gestão de contatos e o índice de maturidade de oportunidades de vendas. No modelo tradicional, os dados do CRM são frequentemente subutilizados e os procedimentos manuais criam gargalos e inconsistências que comprometem a escalabilidade do funil. Nossa metodologia apresenta a solução por meio da comparação de métricas de tempo (redução do ciclo de processo), das pontuações geradas pelos agentes e das probabilidades de conversão.*

1. Introdução

1.1. Sobre o CRM

Customer Relationship Management (CRM) é uma abordagem que integra estratégias, processos e tecnologias para gerenciar interações com clientes, centralizando informações de vendas, marketing e suporte ao longo do ciclo de relacionamento. Entre as soluções disponíveis, destaca-se o *Salesforce Sales Cloud*, plataforma *Software as a Service* (SaaS) líder no segmento, amplamente utilizada por sua capacidade de consolidar dados de múltiplos canais, automatizar fluxos de trabalho e oferecer análises preditivas.

No núcleo do Salesforce, objetos padrão representam entidades-chave: “Lead” (potencial cliente antes da qualificação), “Conta” (empresa ou organização), “Contato” (indivíduo vinculado à conta) e “Oportunidade” (negócio em andamento). Esses objetos podem ser personalizados e inter-relacionados conforme a necessidade.

A plataforma fornece recursos declarativos como Regras de Validação, *Workflow Rules*, Process Builder e Flow Builder, além de opções de desenvolvimento com Apex

e *Lightning Web Components*. O modelo de segurança baseado em perfis, permissões e funções garante controle granular de acesso, enquanto relatórios e *dashboards* oferecem visibilidade em tempo real de indicadores de desempenho (*KPIs*), apoiando decisões baseadas em dados.

1.2. Contextualização e Motivação do Estudo

A área de vendas é responsável por conduzir a captação de clientes, converter *leads* em oportunidades e, consequentemente, gerar a maior parte da receita nas organizações. Em muitas empresas, essa área movimenta uma parcela significativa do faturamento anual, o que torna imprescindível a adoção de processos estruturados e ferramentas de apoio baseadas em tecnologia para tornar o ciclo de vendas mais prático e assertivo. Assim, soluções de *Customer Relationship Management* (CRM) surgem como plataformas que concentram e organizam dados de clientes permitindo as equipes de pré-vendas e pós-vendas a automatizarem atividades como qualificação de *leads*, monitoramento de contas e gestão de contatos. De fato, conforme definido na literatura de CRM, fatores técnicos e de qualidade de dados são determinantes para a adoção de CRM em pequenas e médias empresas, evidenciando o papel fundamental da TI no suporte às operações de vendas [Alshawi and Alalwany 2011]. Há diversos tipos de soluções de CRM, sejam elas oferecidas na modalidade *on-premise* ou em nuvem, que contemplam recursos de integração com outras plataformas, automação de tarefas rotineiras e análises preditivas para auxiliar na tomada de decisões. Com investimentos que ultrapassaram US\$ 39,5 bilhões em 2017, o CRM consolidou-se como o maior segmento de software corporativo [Gartner, Inc. 2018]. No caso específico do *Salesforce Sales Cloud*, o licenciamento básico varia de US\$ 25 (plano *Essentials*) a US\$ 330 (plano *Unlimited*) por usuário ao mês; quando integrados *add-ons* de inteligência artificial e análises preditivas—como *Einstein Sales Analytics* e *Einstein Discovery*—o custo adicional fica em torno de US\$ 75 a US\$ 150 mensais por usuário [Ennaji et al. 2016, Rotovei 2016].

Visando as crescentes demandas de processamento e análise de grandes volumes de dados nos sistemas de CRM, arquiteturas baseadas em sistemas multiagentes têm se mostrado efetivas por permitir a distribuição de tarefas especializadas entre componentes autônomos [Chen et al. 2005]. Em cenários onde diversas fontes de captura de informação — como registros de vendas, interações de suporte e dados de e-mails — precisam ser integradas de forma eficiente, cada agente assume responsabilidades específicas para coletar, filtrar, processar e disponibilizar dados relevantes, reduzindo gargalos de desempenho e melhorando a escalabilidade do sistema [Chen et al. 2005].

De acordo com autores [Chen et al. 2005], propõem um modelo de *On-Line Analytical Mining* (OLAM) em que agentes de aquisição de dados extraem informações transacionais e de atendimento, agentes de OLAP constroem cubos multidimensionais que incluem métricas de receita e índices de satisfação, e agentes de mineração aplicam algoritmos de classificação e agrupamento para detectar padrões de clientes em risco ou possíveis oportunidades de *upsell*. Esses agentes especializados garantem que consultas sobre perfis de clientes ou relatórios de saúde de contas sejam respondidas de forma rápida e escalável, sem sobrecarregar um único componente central. Cada agente comunica-se por meio de protocolos padronizados, compartilhando apenas as informações necessárias ao seu escopo de atuação, o que reduz redundâncias e acelera o fluxo de dados [Chen et al. 2005]. Considerando a abordagem OLAM e outros autores [Rotovei 2016, Ennaji et al.

2016], é proposto neste trabalho que atividades como a qualificação automática de *leads*, a priorização de contas com maior risco de *churn* e a extração de indicadores de maturidade de oportunidades sejam usadas no apoio à tomada de decisões comerciais. Dessa forma, a adoção de uma abordagem multiagentes no contexto do mercado de CRM pode contribuir no tratamento dos dados dos clientes, gerando *insights* para vendedores na tomada de decisão do pipeline de vendas.

O estudo [Alshawi and Alalwany 2011] aponta que, mesmo com investimentos em CRM, muitos dados permanecem subutilizados em tarefas de qualificação, priorização e validação de *leads*, pois problemas de qualidade de dados obrigam a equipe de vendas a correção manual dos registros antes de tomar decisões, resultando em atrasos no processo de vendas. De forma semelhante [Missi et al. 2005], há demonstração de que falhas de integração e governança de dados forçam os vendedores a buscar informações em múltiplos sistemas legados, aumentando o retrabalho e comprometendo a agilidade do pipeline comercial. Também, outros autores [Tazkarji and Stafford 2020] destacam que, na ausência de integração efetiva entre equipes de TI e de vendas, processos automatizados de priorização de *leads* não são definidos, elevando custos operacionais e limitando a escalabilidade das operações de vendas. Dessa forma, mesmo que o investimento em CRM seja significativo, a subutilização dos dados se liga diretamente a gargalos que prejudicam a escalabilidade e a agilidade na conversão de vendas.

A caracterização do uso de dados no fluxo de vendas encontra respaldo no TOE Framework, em que fatores Tecnológicos (competências, infraestrutura e qualidade de dados), Organizacionais (recursos, processos internos e suporte da alta gestão) e Ambientais (pressão competitiva, regulamentação e parceiros) acabam agindo como determinantes críticos nas fases de avaliação, adoção e rotinização do CRM [Cruz-Jesus and Oliveira 2019, Alshawi et al. 2018].

Considerando o contexto da problemática do uso de dados em CRM, o objetivo deste artigo é apoiar a definição de caracterização e utilização de dados de CRM para os processos de fluxo de vendas. Como proposta de solução, é apresentada uma arquitetura multiagentes integrada ao *Salesforce CRM*, composta por quatro agentes autônomos: *LeadAgent*, *AccountAgent*, *ContactAgent* e *OpportunityAgent*. O método de avaliação da solução baseia-se em simulações que compararam duas métricas principais de *Tempo de processo* e *Análise de scores*.

2. Trabalhos Relacionados

Inicialmente, conduziu-se uma revisão de literatura nas bases de conhecimento¹, utilizando as seguintes strings de busca: ("All Metadata":Multi agent) AND ("All Metadata":CRM e a string ("All Metadata":Multi agent) AND ("All Metadata":CRM) AND ("All Metadata":Data")), o que retornou cerca de cinquenta resultados.

A partir dos resultados obtidos, foi realizada uma análise preliminar baseada na leitura de títulos e resumos, com o objetivo de identificar estudos que relacionassem sistemas multiagentes a processos de CRM ou vendas. Essa seleção concentrou-se unicamente na relevância direta ao tema proposto.

¹IEEE Xplore e ACM Digital Library

2.1. Adoção de CRM e o TOE Framework

O modelo Technology–Organisation–Environment (TOE) propõe que a adoção de inovações tecnológicas é influenciada por três contextos: a dimensão tecnológica, que abrange atributos da tecnologia e a qualidade dos dados; a dimensão organizacional, que envolve a disponibilidade de recursos internos e o suporte da alta gestão; e a dimensão ambiental, que contempla as pressões concorrenenciais e regulatórias. Cruz-Jesus et al. [Cruz-Jesus and Oliveira 2019] aplicaram o TOE em 277 empresas e apresentam que a qualidade e integração de dados interferem positivamente, ou negativamente, em todas as fases de adoção de CRM, enquanto pressão competitiva favorece a avaliação inicial, mas pode retardar a adoção [Cruz-Jesus and Oliveira 2019]. Em PMEs, Alshawi et al. [Alshawi and Alalwany 2011] reforçam que fatores técnicos e organizacionais, especialmente a confiabilidade dos dados, são determinantes críticos para o sucesso da implantação de CRM [Alshawi and Alalwany 2011].

2.2. Multi-Agent Aspect-Level Sentiment Analysis (MALSA)

MALSA é um framework multiagente voltado para análise de sentimento em nível de aspecto no contexto de sistemas CRM [Rotovei 2016]. Seu objetivo principal é extrair insights detalhados de feedbacks de clientes, separando opiniões por dimensões específicas do produto ou serviço. A arquitetura do MALSA compreende os *Monitoring Agents*, encarregados de capturar e armazenar eventos de interação — como e-mails, chats e registros de chamadas —; o *Aspect Extraction Agent*, que identifica em cada mensagem termos relacionados a aspectos predefinidos (por exemplo, preço, qualidade e funcionalidade); o *Aspect Aggregation Agent*, responsável por agrupar e normalizar expressões semânticas equivalentes, consolidando o conjunto de termos de cada aspecto; e o *Aspect Sentiment Agent*, que avalia a polaridade (positiva, negativa ou neutra) e a intensidade do sentimento associado a cada aspecto extraído.

No funcionamento do framework, sempre que ocorre a captura de um novo evento pelo *Monitoring Agent*, o texto é encaminhado ao fluxo de análise. Os agentes de extração e agregação isolam e organizam os aspectos identificados, enquanto o agente de sentimento atribui escores quantitativos a cada dimensão. Esses resultados alimentam dashboards de CRM e podem servir de base para agentes de recomendação ou para alarmes de riscos.

Entre os benefícios do MALSA, destaca-se a especificidade na compreensão de quais aspectos impactam a satisfação ou a intenção de compra dos clientes; a modularidade, que permite incluir novos aspectos sem necessidade de reestruturar todo o sistema; e a escalabilidade, pois sua arquitetura distribuída lida de forma eficiente com grandes volumes de texto simultâneos.

2.3. MAR-ALSA: Multi-Agent Recommendation and Aspect-Level Sentiment Analysis

MAR-ALSA estende o framework MALSA, incorporando agentes de recomendação e de análise “what-if” ao pipeline de análise de sentimento por aspecto [Rotovei and Negru 2020]. Como agentes principais, o MAR-ALSA conta com os *Monitoring Agents*, responsáveis por capturar eventos de CRM — como e-mails, notas e mensagens — e manter o histórico de interações; os *Aspect-Level Agents*, que realizam extração de aspectos, agregação semântica e estimativa de polaridade para cada dimensão identificada; e os

Recommendation Agents, que aplicam regras de negócio e cenários “what-if” para sugerir ações de follow-up, descontos ou up-sell com base no estado da oportunidade. Entre as vantagens, destacam-se a arquitetura modular e distribuída, que permite escalabilidade, a atualização dinâmica dos modelos e a integração transparente com o Salesforce CRM.

2.4. Agentes de Mineração Analítica Online (OLAM)

Chen et al. [Chen et al. 2005] apresentam um modelo multiagentes de On-Line Analytical Mining (OLAM) que unifica operações de OLAP e Data Mining em um “armazém de dados generalizado” construído sobre a técnica Multi-Bases Cooperation (MBC). Nesse framework, o *Union Data Field* funciona como um espaço de dados dinâmico, suportado por múltiplos *AtomAgents* (data marts) que podem ingressar ou sair do campo conforme a necessidade de mineração .

O *OLAM Agent* percorre esse espaço, aplicando métodos de mineração multidimensional e multilayer — como classificação, regras de associação, clustering e análise de séries temporais — para descobrir padrões em dados estruturados e não-estruturados (texto, imagens, etc.) . Já o *Decision-making Agent* recebe os padrões extraídos, valida os mesmos e os transforma em possíveis ações de negócio, como por exemplo: modelos de churn, segmentação de clientes e estratégias de cross-sell. Além de ter a possibilidade de gerar sugestões de refinamento do próprio cubo de dados por meio de um ciclo de feedback contínuo.

A abordagem demonstra como arquiteturas multiagentes podem oferecer escalabilidade, tolerância a falhas e capacidade de adaptação online em sistemas CRM, fundamentando a ideia de agentes especializados para automatizar e otimizar fluxos críticos de vendas.

3. Metodologia de Pesquisa

Como métodos de pesquisa, para fundamentação do trabalho foi realizada uma revisão da literatura em bases de dados na identificação de trabalhos que detalhem arquiteturas multiagentes aplicadas a CRM, apresentando frameworks de avaliação e incluir estudos qualitativos sobre adoção de CRM em pequenas e médias empresas. A partir desses estudos, foram extraídas boas práticas de design agentes, métricas de avaliação (como tempo de resposta, precisão dos *scores* e percepção dos usuários).

Com base nos requisitos funcionais e não-funcionais identificados, é proposto o desenvolvimento de um protótipo em Java utilizando o framework JADE, no qual deverão ser implementados quatro agentes principais. A implementação é conduzida de forma incremental, com a elaboração de testes unitários e de integração em um ambiente *Sandbox* do *Salesforce*, pelo metodologia da AUML (*Agent Unified Modeling Language*) [Odell et al. 2000] que ilustrarão a interação prevista entre agentes, CRM e usuários.

Na etapa de avaliação técnica, propõe-se realizar uma validação qualitativa por meio de entrevistas semiestruturadas com participantes que utilizam *Salesforce* em empresas de médio porte. Foram convidados cerca de 10 (dez) vendedores e gestores com pelo menos seis meses de experiência em CRM para testar o protótipo por uma semana. As entrevistas deverão abordar a facilidade de interpretação dos *scores* gerados, a percepção de ganho de produtividade em comparação ao processo manual e o grau de satisfação com a integração ao fluxo de vendas do trabalho existente. Cada entrevista, com duração média

de 30 a 45 minutos, será gravada, transcrita e analisada utilizando codificação temática. Também, é previsto na pesquisa a condução de um estudo de caso em que cada participante utilizará o protótipo por cinco dias para gerenciar um *pipeline* fictício de vinte *leads* e dez oportunidades, respondendo a questionários diários sobre clareza dos escores e rapidez nas decisões.

4. Modelagem Arquitetural multiagentes

A arquitetura proposta integra agentes especializados ao *Salesforce Sales Cloud* para automatizar a qualificação de leads, a avaliação de saúde de contas, a gestão de contatos e o cálculo do índice de maturidade de oportunidades. A adoção de um modelo multiagentes permite estender a plataforma por meio de chamadas a serviços externos, preservando a modularidade e facilitando a manutenção. Dados de Lead, Account, Contact e Opportunity são coletados em objetos padrão, ao passo que cálculos mais sofisticados podem ser delegados a agentes.

4.1. Agentes

O *LeadAgent* extrai informações de perfil, engajamento e recência de cada lead registrado no Sales Cloud. Com base nesses atributos, calcula o *Lead Score* (0–100) por média ponderada, armazena o valor em `Lead_Score__c` e, quando ultrapassa um limiar definido, dispara alertas para a equipe de pré-vendas, diminuindo o tempo de resposta em qualificações.

O *AccountAgent* agrupa valor das oportunidades em aberto, frequência de interações nos últimos 90 dias e recência da última atividade para cada conta. Esses indicadores são normalizados e combinados por meio de pesos preestabelecidos, resultando em um *Health Score* (0–100) que identifica contas em risco de churn ou de alta prioridade. Quando necessário, esse agente requisita análises OLAM externas para ajustar parâmetros, retornando o valor ao campo `Account_Health_Score__c`.

O *ContactAgent* preenche campos ausentes por meio de serviços de enriquecimento de dados (por exemplo, Data Cloud Enrichments) e avalia a qualidade dos registros. Além disso, aplica análises de sentimento em interações registradas (e-mails, casos), destacando possíveis insatisfações. Os resultados são armazenados em `Contact_Data_Quality__c` e `Contact_Sentiment__c`, apoiando a limpeza periódica da base de contatos.

O *OpportunityAgent* identifica o estágio atual de cada oportunidade e calcula o *Maturity Index* por meio da soma dos pesos dos estágios já concluídos, acrescida da fração correspondente ao estágio em andamento. O índice final (0–100) é salvo em `Opportunity_Maturity__c`; quando estiver abaixo de parâmetros críticos, o agente aciona fluxos de follow-up automático, prevenindo estagnação de negócios.

4.2. Integração e Fluxos de Comunicação

Os agentes interagem por meio de *Platform Events* no *Event Bus* do Salesforce. Cada agente registra, em um repositório de serviços (implementado via *Custom Metadata Types*), a interface responsável pela execução (classe *Apex* ou *URL* externa). Alterações em objetos padrão disparam eventos (por exemplo, `LeadCreated__e`), que são capturados por Triggers ou *Record-Triggered Flows* para invocar o agente correspondente. Para tarefas que envolvem grandes volumes de dados, como OLAM, são usados *Batch Apex* ou serviços

externos, retornando resultados via *Bulk API*. Em cenários de baixa volumetria, os cálculos ocorrem diretamente em Apex, garantindo resposta imediata aos eventos.

5. Proposta de Solução

Esta seção descreve como a proposta multiagentes se aplicaria em um cenário de CRM. Imagine-se uma empresa que utiliza o *Salesforce* para gerenciar seu pipeline de vendas, mas enfrenta dificuldades de utilização com o volume de *leads* e o acompanhamento de oportunidades.

Quando um novo lead é inserido, o *LeadAgent* calcula automaticamente um *Lead Score* a partir de perfil, engajamento e recência, gravando o resultado no *Salesforce* sem intervenção manual. Em seguida, o *AccountAgent* avalia as contas associadas a esse lead, gerando um *Health Score* com base na recência das últimas interações, na frequência de atividades e no valor total de oportunidades em aberto. Se o *Health Score* ficar abaixo de um limiar crítico, o agente registra uma tarefa automática para alerta ao gestor. Logo após, o *ContactAgent* verifica a consistência dos dados de contato, sugerindo correções via notificações no *Salesforce*. Por fim, o *OpportunityAgent* monitora as oportunidades associadas às contas qualificadas e calcula, periodicamente, um Índice de Maturidade conforme o progresso das etapas do funil de vendas.

Durante o uso da solução, registram-se logs sucintos para cada agente: número de leads pontuados, contas sinalizadas com alerta, contatos corrigidos e oportunidades com Índice de Maturidade acima de determinado valor parametrizado para a empresa. Esses registros ilustram o comportamento esperado, como, por exemplo: “o *LeadAgent* pontuou cinquenta leads em duas horas e direcionou para pré-vendas aqueles com escore acima de 90”. Ao processar um determinado lote de vinte leads, por exemplo, o *LeadAgent* atua sequencialmente, o *AccountAgent* atualiza *Health Scores* a cada periodicidade parametrizada e o *ContactAgent* sinaliza automaticamente contatos inválidos, enquanto o *OpportunityAgent* ajusta os índices de maturidade parametrizado conforme o status das oportunidades.

6. Conclusões e Perspectivas Futuras

Nessa proposta, foi apresentada uma arquitetura conceitual de solução multiagentes integrada ao *Salesforce CRM*, com a possibilidade de automatizar etapas críticas do pipeline de vendas, como qualificação de leads, avaliação de saúde de contas, validação de contatos e monitoramento de oportunidades com a finalidade de otimizar os fluxos, captar novas oportunidades de venda e prevenir gargalos de processo. Apesar de ainda não dispor de uma implementação finalizada e demais etapas da pesquisa como entrevista e estudo de caso, este estudo demonstrou de forma clara os agentes necessários, as interações previstas com o ambiente *Salesforce* e as métricas que deverão ser coletadas para avaliar desempenho e usabilidade.

A abordagem qualitativa proposta está em andamento, por meio de entrevistas semiestruturadas com análise temática e estudo de caso com usuários reais, garantirá que a percepção dos profissionais de CRM seja incorporada ao refinamento da solução, apontando requisitos de interface, ajustes nos pesos de pontuação e necessidades de adaptação ao fluxo de trabalho existente.

Como trabalhos futuros é definido a condução de um estudo empírico com usuários de diferentes perfis (vendedores, gestores de CRM e analistas de dados) para avaliar de maneira mais abrangente a aceitação, a utilidade e o impacto nos indicadores de produtividade e satisfação. Outras pesquisas futuras poderão investigar arquiteturas híbridas, combinando agentes deliberativos com microsserviços escaláveis, além de experimentar diferentes estratégias de mensageria (por exemplo, *Kafka* ou *RabbitMQ*) para melhorar a resiliência e a escalabilidade em volumes de dados. Outras tecnologias e integrações com outras plataformas de CRM também podem ser consideradas em propostas como trabalhos futuros.

Referências

- Alshawi, S. and Alalwany, N. (2011). Critical success factors for crm implementation in smes. In *Proceedings of the 2011 International Conference on Industrial Engineering and Operations Management*, page ...–....
- Alshawi, S., Missi, F., and Irani, Z. (2018). Organisational, technical and data quality factors in crm adoption — smes perspective. *Information Systems Frontiers*, 20(1):1–13.
- Chen, M., Chen, Y., and Hsu, W. (2005). Agent-based on-line analytical mining in crm system. *Decision Support Systems*, ...(...):...–....
- Cruz-Jesus, F. and Oliveira, R. (2019). Organisational, technical and data quality factors in crm adoption — smes perspective. *Industrial Management Data Systems*, ...(...):...–....
- Ennaji, F. Z., El Fazziki, A., El Alaoui El Abdallaoui, H., Sadiq, A., Sadgal, M., and Benslimane, D. (2016). Multi-agent framework for social crm: Extracting and analyzing opinions. In *Proceedings of the 4th International Conference on Control Engineering & Information Technology (CEIT-2016)*, Hammamet, Tunisia. IEEE.
- Gartner, Inc. (2018). Market share analysis: Crm applications, worldwide, 2017. Relatório Gartner.
- Missi, F., Alshawi, S., and Fitzgerald, G. (2005). Why crm efforts fail? a study of the impact of data quality and data integration. In *Proceedings of the 38th Annual Hawaii International Conference on System Sciences (HICSS)*. IEEE Computer Society Press.
- Odell, J., Parunak, H. V. D., and Bauer, B. (2000). Extending UML for agents. In *Proceedings of the Agent-Oriented Information Systems Workshop at the 17th National Conference on Artificial Intelligence*.
- Rotovei, D. (2016). Multi-agent aspect level sentiment analysis in crm systems. In *18th International Symposium on Symbolic and Numeric Algorithms for Scientific Computing (SYNASC)*, page ...–.... IEEE.
- Rotovei, D. and Negru, A. (2020). Multi-agent recommendation and aspect level sentiment analysis in b2b crm systems. *Expert Systems with Applications*, ...(...):...–....
- Tazkarji, M. Y. and Stafford, T. (2020). Reasons for failures of crm implementations. *IEEE Transactions on Computational Social Systems*. in press.