



# SMART iCash: Estratégias Inovadoras com Machine Learning para Otimizar a Gestão de Inadimplência no Setor de Energia

**Tema:** Recuperação de crédito - Inadimplência

**Autores:** Bruno Nascimento (SEW), Vivian Silva Magalhaes (CEMIG)

**Co-Autores:** Jamilton Carvalhaes (SEW), Gabriel Cordeiro (SEW)

**Empresa:** Choice Technologies SA

---

## Resumo

Como um dos pilares do desenvolvimento econômico, o setor de energia enfrenta desafios significativos intensificados pelos impactos da pandemia global. Entre esses desafios, destacam-se a desaceleração econômica, a redução na demanda por energia, a queda nos preços e o aumento expressivo da inadimplência (PROSKURYAKOVA, L., KYZYNGASHEVA, E., & STARODUBTSEVA, A., 2021).

O crescimento da inadimplência exige que concessionárias de energia busquem constantemente soluções para melhorar a eficiência operacional e gerir de forma estratégica as dívidas em aberto. Nesse contexto, a adoção de tecnologias inovadoras desempenha um papel crucial no aprimoramento dos processos de cobrança e na redução de perdas financeiras.

Este artigo apresenta os resultados alcançados pela CEMIG DISTRIBUIÇÃO S.A. com a implementação da plataforma SMART iCash, uma solução voltada para otimizar ações de cobrança no gerenciamento da inadimplência. Utilizando scores preditivos baseados em Machine Learning, a plataforma analisa o histórico de pagamentos, dados de consumo e localização do cliente, possibilitando uma abordagem mais eficiente e personalizada no processo de cobrança.

## 1. Introdução

A cobrança de faturas não pagas é uma tarefa complexa para empresas de utilities que buscam continuamente melhorias. Os sistemas de cobrança para utilities têm um recurso de regras de cobrança que determinam qual ação de cobrança (por exemplo, SMS, email, carta de aviso, desconexão) e quando deve ser acionada.

O problema é que, em geral, a mesma regra de cobrança é aplicada para todos os clientes, significando ações de cobrança e prazos iguais e, em consequência, desperdício de recursos na implementação das ações por parte das concessionárias (NASCIMENTO, Bruno S.; MAIA, Denis; ALMADA, Lucas., 2021). Para contornar esse problema, a plataforma **SMART iCash**[1] utiliza Machine Learning – modelos de scoring – para obter regras de cobrança individualizadas.

Com a utilização dos modelos de scoring é possível, por exemplo, obtermos um ranking individualizado para cada cliente. Como resultado, pode-se evidenciar de forma prática que muitas vezes ações que possuem custo de execução alto podem ser desconsideradas, possibilitando dessa forma a otimização da alocação de capital para recuperar mais receita.

No caso da CEMIG DISTRIBUIÇÃO S.A. (CEMIG), após a adoção da plataforma **SMART iCash**, do fornecedor SEW, obteve-se um aumento da efetividade 15% para ações de cobrança do tipo e-mail e 6% para ações de cobrança do tipo SMS quando comparado antes e depois da implementação. Embora ainda há espaço de melhorias, a otimização e flexibilização do processo permitiu elevar a eficiência das cobranças, evitando desperdícios financeiros decorrentes da não efetividade das ações de cobrança. Nas próximas seções serão apresentados o contexto para adoção da solução, os principais módulos, bem como uma comparação dos resultados obtidos em relação a volumetria e efetividade.

[1] Maiores informações podem ser obtidas em: <https://www.choicetech.ai/cash-collection.html>

## 2. Desenvolvimento

### 2.1. Cenário

A CEMIG conta com uma equipe dedicada na Gerência de Recuperação de Receitas, cuja principal responsabilidade é analisar e definir estratégias e réguas de cobrança para faturas de energia elétrica em atraso. Essa régua estabelece as ações prioritárias para incentivar o pagamento das faturas pendentes. De maneira geral, a régua é padronizada para todos os clientes, com alguns prazos mínimos determinados pela regulação vigente. A Figura 01 ilustra um exemplo de como essa régua de cobrança é estruturada.




Figura 01 – Exemplo ilustrativo de uma Régua de Cobrança

A CEMIG adota diversos tipos de ferramentas para execução das ações de cobrança:

- E-mail;
- SMS;
- Negativação;
- Corte;
- Carta Cobrança;
- Cobrança Administrativa;
- Protesto;
- Cobrança Judicial.

Essas ações de cobrança possuem custos atrelados e aplica-las a todos os clientes indiscriminadamente, acarretaria em desperdício de recursos. Das faturas emitidas de baixa tensão por mês pela CEMIG, 25% são pagas com atraso superior a 3 dias, e um percentual dessas faturas vão para a PECLD – Perdas Estimadas em Crédito de Liquidação Duvidosa[1].

Conforme políticas internas da CEMIG e ditames da ANEEL (ANEEL, 2021), a partir de 30 dias após o vencimento da fatura, a Unidade Consumidora já pode ter sua energia elétrica suspensa (Corte), sendo que este prazo para realização do corte se estende até 90 dias após o vencimento.

Após este período, o valor da fatura é revertido para a PECLD, cujo retorno depende de cobranças administrativas e judiciais, e são de mais difícil recuperação.

Um ponto fundamental da estratégia de cobrança é o entendimento que as ações mais efetivas tendem a ter custos maiores e que quanto mais tempo uma dívida fica em aberto (Day Sales Outstanding – DSO) maior é o prejuízo na concessionária (Figura 02).

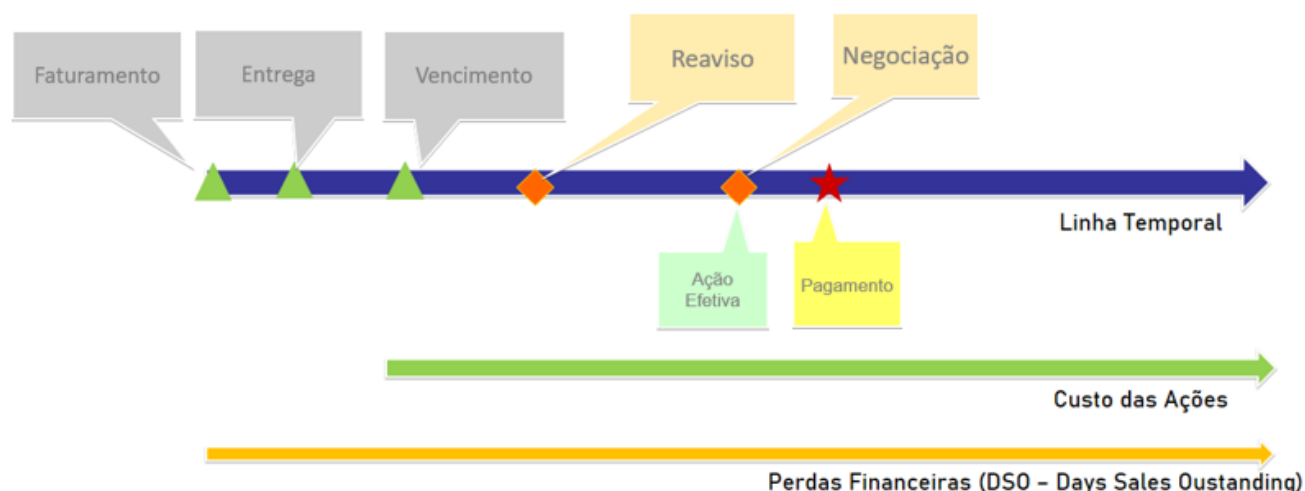


Figura 02 – Exemplo ilustrativo de aplicação da Régua de Cobrança em um cliente

Para evitar que os recursos financeiros sejam desperdiçados, a CEMIG implantou a plataforma **SMART iCash**. Esta solução possibilita a maximização do fluxo de caixa fornecendo informações perspicazes sobre a ação de cobrança mais adequada para alcançar clientes inadimplentes.

## 2.2. Revenue Intelligence® for Cash Collection

### 2.2.1. Descrição Geral

**SMART iCash** é uma plataforma de aplicativos integrados que abrange os aspectos relacionados à proteção de receita das utilities. Alguns recursos gerais da plataforma, comuns a todos os aplicativos, são listados abaixo:

- o Um sistema baseado na web;
- o Acesso através de um navegador da Internet;
- o Interface amigável (não requer conhecimento de programação);
- o Configurado para ser acessado via SSL;
- o Multilanguage (Inglês / Português / Espanhol);
- o Nenhum conhecimento de SQL ou programação requerido para operação.

A solução é totalmente personalizável e inclui uma interface de usuário altamente intuitiva (figura 03).

Nome	Tipo de ação	Status	Criada em	Selecionados	Executados	Cancelados	Cancelamento solicitado	Pendentes	Débito aberto (R\$)	Débito pago (R\$)	Ações efetivas	Ações parcialmente efetivas
20230726-53- Negativação-AUTO	Negativação	Em Progresso	24/07/2023	30.000	0	0	0	30.000	19.172.529	0	0	0
20230726-48- Protesto-AUTO	Protesto	Em Progresso	24/07/2023	10.000	0	0	0	10.000	5.000.600	0	0	0
20230726-43-E-mail cobrança 5º envio - contrato ativo-AUTO	E-mail Cobrança	Em Progresso	24/07/2023	1.162	0	0	0	1.162	2.953.310	0	0	0
20230726-42-E-mail cobrança 5º envio - contrato ativo-AUTO	E-mail Cobrança	Em Progresso	24/07/2023	2.602	0	0	0	2.602	1.651.319	0	0	0
20230726-23-E-mail Cobrança 4º envio-AUTO	E-mail Cobrança	Em Progresso	24/07/2023	4.011	0	0	0	4.011	4.052.765	0	0	0
20230726-18-E-mail Cobrança 1º envio 5-AUTO	E-mail Cobrança	Em Progresso	24/07/2023	20.602	0	0	0	20.602	32.286.941	0	0	0

Figura 03 – Exemplo de interface da plataforma **SMART iCash**

## 2.2.2. Modelos de Machine Learning

O Revenue Intelligence for Cash Collection tem seu banco de dados atualizado com dados adquiridos de múltiplas fontes de dados corporativas. Normalmente, os dados podem ser extraídos da medição (leituras de consumo mensais), faturamento, ordens de serviço e CRM, GIS e outros sistemas. Após a conclusão do processo de carga de dados, o **SMART iCash** executa regras e modelos de inteligência computacional/Machine Learning.

Os modelos de Machine Learning embarcados na plataforma levam em conta o histórico de pagamentos do cliente, informações de consumo, e até mesmo a localização. Os modelos têm como base artigos de referência dentro do mesmo contexto (NASCIMENTO, Bruno S.; MAIA, Denis; ALMADA, Lucas., 2021; LESSMANN, Stefan et al.; 2015; MUNKHDALAI, Lkhagvadorj et al., 2019; KIM, Yoon Seong; SOHN, So Young., 2004). Entre os modelos disponíveis, destacam-se:

- 1) **Modelos de propensão para inadimplência:** é o modelo que a partir dos consumidores adimplentes, prediz a probabilidade de um consumidor se tornar inadimplente, considerando os prazos de 30, 60 e acima de 90 dias.
- 2) **Modelo de resposta as ações de cobrança:** é o modelo que prediz a probabilidade de pagamento mediante uma ação a ser realizada.
- 3) **Modelo de resposta espontânea:** é o modelo que prediz a probabilidade de um cliente de forma proativa se regularizar sem a necessidade de realizar uma ação prevista na régua de cobrança.
- 4) **Modelos de clusterização para corte:** são modelos georreferenciados para otimização com objetivo de maximizar da recuperação da receita no processo de corte.
- 5) **Modelos de roteirização para o corte:** é o modelo que indica a melhor rota para as equipes de campo executarem os serviços de corte.

Para os modelos supracitados (1), (2) e (3) foram utilizadas combinações de algoritmos de classificação. Dado o grande número de classificadores, não é possível descrever todos os algoritmos em detalhes. No entanto, categorizamos os algoritmos em: baseados em árvore de decisão (por exemplo, Random Forest, XGBoost, LightGBM, Catboost, ExtraTree), métodos de regressão estatística (por exemplo, Logistic Regression); Estimadores de probabilidade (por exemplo, Naive Bayes). A partir dos resultados de todos os algoritmos de Machine Learning individualmente, usamos uma abordagem de comitê de algoritmos para obter o melhor score preditivo. A abordagem do comitê visa melhorar o desempenho da classificação construindo uma combinação da saída de vários classificadores, em vez de aplicar uma única técnica. A ideia

é que algoritmos diferentes tenham visões diferentes sobre os mesmos dados e possam se complementar (NASCIMENTO, Bruno S.; MAIA, Denis; ALMADA, Lucas., 2021).

Já os modelos (4) e (5) utilizam o conceito de algoritmos gulosos, no qual produzem soluções ótimas localmente que se aproximam de uma solução ótima global em um período de tempo razoável (BLACK, Paul E., 2012).

### 2.2.3. Aplicativos implantados

A plataforma é composta por aplicações (Apps) tendo por objetivo atender em detalhes os requisitos dos processos de redução da inadimplência. Os principais Apps utilizados são:

- Customer Analysis
- Performance Analysis
- Selection
- Customer Scoring
- Geo Disconnection

#### 2.2.3.1. *Customer Analysis*

Apresenta todos os detalhes de cada cliente, empoderando o usuário de negócio entender a experiência que cada consumidor está tendo, onde toda informação está disponível a partir do agrupamento de diferentes fontes de sistemas em uma única tela. O Customer analysis provê capacidades de pesquisa detalhadas com base dos campos disponíveis na base de dados.

Principais características

- Entender a experiência do cliente;
- Realizar pesquisas avançada, correlacionando diversas propriedades dos consumidores;
- Integrações com Google Maps e Street View;
- Visualizar contratos e detalhar faturas relacionadas;
- Visualizar séries temporais:
  - Débitos,
  - Pagamentos,
  - Parcelamentos,
  - Eventos de ações de cobrança,
  - Eventos de Ordens de Serviço, etc.

#### 2.2.3.2. *Performance Analysis*

Apresenta uma série de conjuntos pré-definidos de relatórios, tais como: “Desempenho de cada ação de cobrança”, “Níveis de inadimplência”, “Monitoramento das equipes de corte” ou “Dívida total por diferentes dimensões” são exemplos de relatórios disponíveis nesta App.

Principais características

- Monitorar por meio de uma interface intuitiva:
  - Execução de Processos de Negócio em detalhe
  - Desempenho das ações de cobrança
  - Níveis de inadimplência
  - Rendimento das equipes de corte
  - Saldo, débitos e parcelamentos

#### 2.2.3.3. *Selection*

Apresenta funcionalidades para priorizar ações de cobrança com base em critérios definidos por Machine Learning (apresentados na Seção 2.2.2).

O app exibe os clientes em diferentes opções de visualização (mapa, lista, gráfico, etc.), exibe previsões para ajudar os usuários a selecionar os melhores clientes para sofrerem suas respectivas ações de recuperação de receita, de acordo com os critérios previamente definidos. Os clientes podem ser analisados individualmente ou agrupados. A partir do Selection é possível revisar e refinar a lista de consumidores antes de finalizá-la e enviá-la para execução. Além disso, é possível realizar programações prévias para disparo diário, semanal ou mensal de determinadas ações de cobrança.

Após a seleção, os usuários podem acompanhar a execução e o que está pendente, incluindo uma opção para cancelar as ações antigas selecionadas, mas não realizadas (pendentes).

Principais características

- Selecionar os clientes com alto impacto financeiro;
- Gerar listas ótimas para cada tipo de ação de cobrança;
- Agendar seleção automaticamente para cada padrão (ação de cobrança);
- Listar os contratos candidatos a ações de cobrança com suas propriedades e scores estatísticos.
- Relacionar a posição do Contrato/UC com os scores estatísticos e permite que a seleção seja feita no mapa.
- Acompanhar a execução e os resultados da ação, podendo cancelar ações não executadas ou de baixo desempenho.

#### 2.2.3.4. *Customer Scoring*

Apresenta funcionalidades para criação de padrões de cobrança. Possui uma interface intuitiva que permite aos usuários arrastar e soltar elementos para criar regras de negócio e simular resultados esperados. A simulação dá visibilidade dos resultados esperados após executar as ações de cobrança em termos de efetividade e produtividade. Cada regra está associada a um determinado tipo de ação de cobrança, dando flexibilidade de criar diferentes estratégias a serem incorporadas na régua de cobrança. A Figura 04 apresenta um exemplo da interface para criação de uma regra para ação de cobrança “E-mail”.

Principais características

- Transformar conhecimento tácito em regra de negócio (base de conhecimento);
- Simular regras com base no histórico de ações de cobrança;
- Executar e salvar os cálculos necessários para todos os atributos relacionados a um cliente;



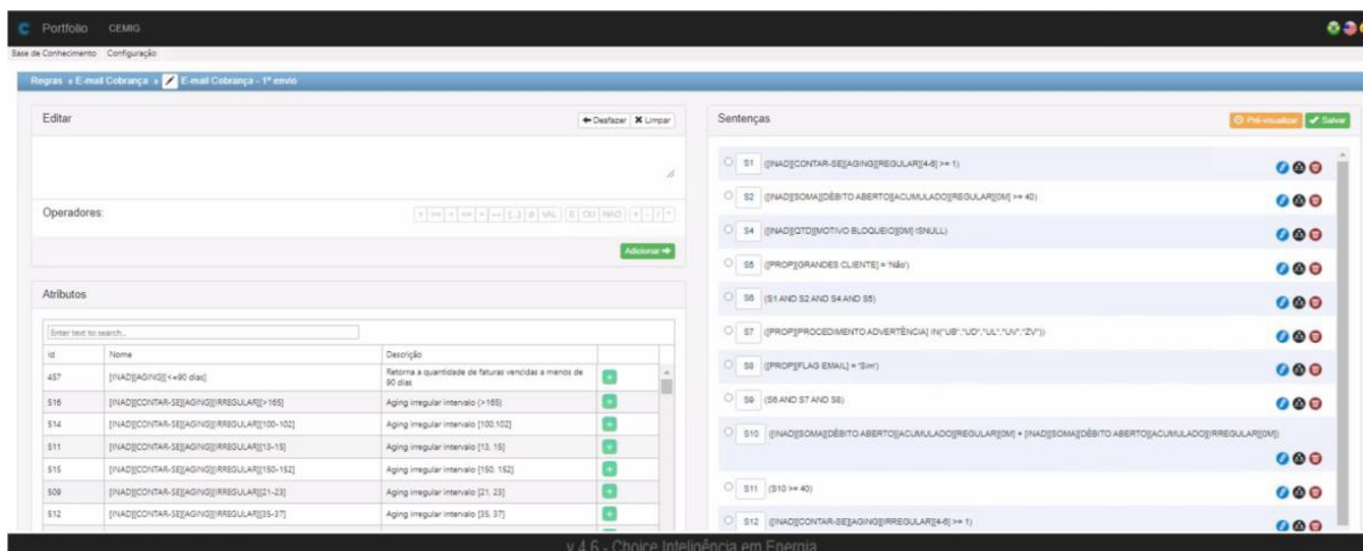


Figura 04 – Interface App Customer Scoring – Criação de Regras

#### 2.2.3.5. Geo Disconnection

Apresenta funcionalidades para executar modelos de otimização com objetivo de obter seleções ótimas de alvos de corte com base em georreferenciamento. Esta app tem como base o artigo (SOARES, Welligton F. C.; PIMENTA, C., 2020). A app possui diversos algoritmos para identificar cluster ótimos para execução de serviços de corte – suspensão do fornecimento de energia elétrica.

Principais características

- Criar agendamentos recorrentes;
- Distribuir as equipes de campo automaticamente em diferentes regiões com objetivo de garantir a máxima recuperação da receita;
- Roteirização para minimizar o deslocamento das equipes de campo;
- Maximização do processo de recuperação da receita utilizando algoritmos de Machine Learning;

#### 2.3. Resultados obtidos

Para fins de comparação entre o ANTES e o DEPOIS da adoção da plataforma **SMART iCash** para gestão da inadimplência, foram analisados dados reais de um período de 12 meses para as ações do tipo “email” e “SMS”. Cabe destacar que a plataforma entrou em produção na CEMIG a partir de junho de 2021.

Os períodos considerados para a análise são:

- **ANTES:** De fevereiro de 2020 a janeiro de 2021 (sem o uso da plataforma);
- **DEPOIS:** De fevereiro de 2022 a janeiro de 2023 (com o uso da plataforma).

##### 2.3.1. Resultados para a Ação de Cobrança via E-mail

O Gráfico 01[2] mostra que a adoção da plataforma resultou m:

- **Aumento de 55% no volume das ações de cobrança via e-mail** em comparação aos períodos ANTES e DEPOIS.
- **Aumento de 15 pontos percentuais na efetividade total**, elevando significativamente a taxa de sucesso no recebimento de pagamentos. A efetividade foi calculada considerando os contratos que efetuaram pagamento em até 7 dias após o envio da ação de cobrança.

Esses resultados indicam que, mesmo diante do aumento expressivo na volumetria, a plataforma permitiu aprimorar a efetividade das ações, otimizando a recuperação de receitas. Essa variação positiva reflete o impacto direto da utilização de scores preditivos e estratégias personalizadas na gestão das cobranças. É importante ressaltar que o período pós COVID-19 alavancou a inadimplência, entretanto, mesmo com o crescente aumento da volumetria obteve-se aumento percentual da efetividade.




Gráfico 01 – Ação de cobrança e-mail ANTES x DEPOIS

Gráfico 01 – Ação de cobrança e-mail ANTES x DEPOIS

2.3.2. Resultados para a Ação de Cobrança via SMS

Seguindo a mesma tendência, o Gráfico 02 destaca os seguintes resultados para as ações de cobrança via SMS:

- **Aumento de 492% no volume total das ações de cobrança via SMS**, demonstrando a escalabilidade e alcance da estratégia após a adoção da plataforma.
  - **Aumento de 6 pontos percentuais na efetividade total**, passando de 27% para 33%. A análise também considerou os contratos que pagaram até 7 dias após o envio da cobrança.
- Esse aumento substancial na volumetria, aliado à melhoria da efetividade, evidencia a capacidade da plataforma de gerenciar grandes volumes de ações de forma eficiente, mesmo em cenários de inadimplência elevada.






Gráfico 02 – Ação de cobrança SMS ANTES x DEPOIS

Gráfico 02 – Ação de cobrança SMS ANTES x DEPOIS

Os resultados positivos para ambas as ações (E-mail e SMS) refletem os benefícios diretos da utilização da plataforma **SMART iCash**. Por meio de uma gestão ágil e do uso de scores preditivos, foi possível:

- **Individualizar as regras de cobrança**, tornando-as mais assertivas e adaptadas ao perfil dos clientes.
- **Maximizar a alocação de capital**, garantindo maior retorno sobre as ações de cobrança realizadas.
- **Aumentar a recuperação de receitas**, mesmo diante do cenário desafiador do período pós-pandemia, que trouxe aumento significativo na inadimplência.

A adoção de estratégias digitais avançadas, aliadas ao Machine Learning, demonstrou ser uma solução robusta e eficaz para o enfrentamento dos desafios operacionais no setor de energia.

[1] Estimativa para possíveis perdas que poderão ocorrer do não recebimento de créditos oriundos de transações comerciais realizadas pela Empresa.

[2] Seguindo uma decisão estratégica, as quantidades absolutas das ações de cobrança realizadas pela CEMIG foram omitidas dos Gráficos 01 e 02.

### 3. Conclusão

Este artigo apresentou a implementação da plataforma **SMART iCash** na gestão da inadimplência pela CEMIG, destacando seu papel estratégico na otimização do processo de cobrança. A plataforma foi desenvolvida para aliar flexibilidade e eficiência, permitindo o uso de modelos preditivos de scoring baseados em Machine Learning, capazes de criar regras de cobrança individualizadas. Como resultado, observou-se

um aumento significativo no retorno das ações, evidenciado por um maior número de clientes quitando seus débitos devido à maior precisão na seleção dos alvos de cobrança.

Um dos principais benefícios proporcionados pela solução foi a agilidade operacional. A plataforma oferece uma interface intuitiva, permitindo à área de negócios criar ou ajustar regras e parametrizações sem a necessidade de suporte contínuo da equipe de TI, simplificando e acelerando o processo de cobrança.

Os resultados comparativos entre os períodos ANTES e DEPOIS da adoção da SMART iCash, com foco nas ações de cobrança via e-mail e SMS, demonstram os impactos positivos da solução. Apesar do aumento expressivo na volumetria das ações, a maior assertividade na escolha dos alvos resultou em uma recuperação de débitos mais eficiente e, consequentemente, na redução das perdas financeiras convertidas em PECLD. Isso evidencia a capacidade da plataforma de otimizar a alocação de OPEX em clientes com maior probabilidade de resposta às ações de cobrança.

Outro destaque é o potencial da **SMART iCash** no monitoramento e controle das ações. A aplicação contínua de modelos preditivos permite não apenas a individualização das regras de cobrança, mas também uma postura mais proativa da concessionária. Relatórios customizados possibilitam o acompanhamento detalhado dos resultados, permitindo identificar desvios em tempo hábil e ajustar estratégias para garantir o desempenho esperado. Além disso, a solução fornece estimativas probabilísticas de receita, ampliando a previsibilidade e o controle financeiro.

Conclui-se que a adoção da plataforma **SMART iCash** foi essencial para elevar a eficácia da gestão de inadimplência, impulsionada pela combinação de uma equipe altamente qualificada e a implementação de novos processos estratégicos. Essa integração permitiu avanços significativos no uso de tecnologias digitais e na modernização das estratégias de cobrança no setor de energia, consolidando a CEMIG como referência em inovação e eficiência operacional.

## 4. Referências bibliográficas

ANEEL, Agência Nacional de Energia Elétrica. Resolução Normativa N°1000/2021 – Condições Gerais de Fornecimento de Energia Elétrica. Brasília, DF - Brasil. 2021. Disponível em: <https://www2.aneel.gov.br/ce-doc/ren20211000.html>.

BLACK, Paul E. greedy algorithm, Dictionary of Algorithms and Data Structures. **US Nat. Inst. Std. & Tech Report**, v. 88, p. 95, 2012.

SOARES, Welligton F. C.; PIMENTA, C. Seleção ótima de alvos de corte usando georreferenciamento: desenvolvimento SAP/CCS. Ponta Grossa – PR : Atena Editora, 2020. A aplicação do Conhecimento Científico na Engenharia Elétrica, Capítulo: 7, p. 75-88. Disponível em: <https://repositorio.ufc.br/handle/riufc/64504>.

LESSMANN, Stefan et al. Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research. **European Journal of Operational Research**, v. 247, n. 1, p. 124-136, 2015. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0377221715004208>.

MUNKHDALAI, Lkhagvadorj et al. An empirical comparison of machine-learning methods on bank client credit assessments. **Sustainability**, v. 11, n. 3, p. 699, 2019. Disponível em: <https://www.mdpi.com/2071-1050/11/3/699>.

NASCIMENTO, Bruno S.; MAIA, Denis; ALMADA, Lucas. Applying Machine Learning to Improve Collection and to Reduce Write-Offs in Utilities. In: 2021 International Conference on Artificial Intelligence and

Blockchain Technology (AIBT). IEEE, 2021. p. 1-5. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9694093>.

PROSKURYAKOVA, Liliana; KYZYNGASHEVA, Elena; STARODUBTSEVA, Alena. Russian electric power industry under pressure: Post-COVID scenarios and policy implications. Smart Energy, v. 3, p. 100025, 2021. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2666955221000253>.

KIM, Yoon Seong; SOHN, So Young. Managing loan customers using misclassification patterns of credit scoring model. **Expert Systems with Applications**, v. 26, n. 4, p. 567-573, 2004. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0957417403001945>.