



Lisbon School
of Economics
& Management
Universidade de Lisboa

Mestrado em
MÉTODOS QUANTITATIVOS PARA A
DECISÃO ECONÓMICA E EMPRESARIAL

PROJETO

APLICAÇÃO DE *BUSINESS INTELLIGENCE* EM *AIRTIME*
CREDIT

MIGUEL CAEIRO ARSÉNIO

Orientação: Prof. Carlos Costa

JUNHO - 2026

GLOSSÁRIO

AI	Artificial Intelligence
ATC	Airtime Credit
AVG	Average
BI	Business Intelligence
DAX	Data Analysis Expressions
DSR	Design Science Research
DWH	Data Warehouse
ETL	Extract, Transform, and Load
FCST	Forecast
KPI	Key Performance Indicator
ID	Identificador Digital
ML	Machine Learning
OLAP	Online Analytical Processing
OLTP	Online Transaction Processing
SMS	Short Message Service
SQL	Structured Query Language
USSD	Unstructured Supplementary Service Data
TFM	Trabalho Final de Mestrado
3NF	Terceira Forma Normal

RESUMO

Este Trabalho Final de Mestrado (TFM) aborda a criação, o desenvolvimento e avaliação de uma solução de *Business Intelligence* (BI) dedicada à monitorização da performance de um portfólio de projetos em *Airtime Credit* (ATC). O principal foco deste trabalho encontra-se na resolução de uma ineficiência operacional crítica, visto que o acompanhamento dos indicadores de desempenho e de risco era realizado através de um processo manual, fragmentado e assente em folhas de cálculo de *Excel*, o que proporciona um ciclo de análise demorado. Este processo anterior limitava a capacidade da equipa de negócio em tomar decisões rápidas, proativas e eficientes, comprometendo a identificação atempada de anomalias na infraestrutura do serviço e na correção de desvios face às metas mensais estabelecidas pela equipa. Com o objetivo de melhorar estas análises, este TFM teve como finalidade criar e implementar uma plataforma analítica automatizada em *Power BI* capaz de fornecer *dashboards* diários dos principais indicadores de desempenho de cada projeto do portfólio.

Guiado pela metodologia *Design Science Research* (DSR), o processo de investigação deste projeto seguiu as fases iterativas do ciclo de vida para o desenvolvimento de um artefacto de base tecnológica. O método escolhido envolveu a exploração do *Data Warehouse* (DW) da organização para a extração e estruturação de dados heterogêneos através de processos de engenharia e modelação de dados. Foi criado um modelo relacional multidimensional baseado num esquema em estrela, que recorreu a tabelas agregadas para maximizar a performance analítica do artefacto. Também se recorreu à linguagem *Data Analysis Expressions* (DAX) para codificar a camada de inteligência do negócio, desenvolvendo fórmulas para o cálculo de importantes KPIs de performance, projeções mensais de metas e análises temporais de recuperação das dívidas dos utilizadores.

Os resultados da demonstração do artefacto criado em ambiente empresarial real comprovaram a utilidade e a eficácia da solução proposta. Em relação à eficiência registou-se uma redução drástica e altamente significativa no tempo de ciclo necessário para a extração, tratamento e visualização dos dados diários e semanais, proporcionando ao analista um maior tempo de execução para tarefas de interpretação estratégica. Na precisão e integridade dos dados do artefacto, a auditoria e validação cruzada efetuada

demonstrou uma convergência bastante sólida face aos métodos tradicionais, onde as ligeiras discrepâncias encontradas em determinados projetos são empresarialmente e estatisticamente irrelevantes para a análise operacional e financeira, não comprometendo a fidedignidade da plataforma.

Em suma, este trabalho cumpriu com sucesso os seus principais objetivos, entregando uma solução tecnológica validada que representa um salto qualitativo na eficiência operacional da organização da equipa de ATC. Nas principais limitações do artefacto criado, destaca-se a dependência da estabilidade e atualização das infraestruturas de dados de origem. Por fim, para trabalhos futuros neste âmbito, sugiro a evolução do sistema para uma vertente preditiva através da integração de modelos em *Machine Learning* (ML) para a antecipação do risco de dívida e a adoção de ferramentas em Inteligência Artificial (AI) para a automatizar autonomamente os relatórios de gestão semanais com base no artefacto.

Palavras-chave: *Business Intelligence, Airtime Credit, Suporte à Decisão, Automação Analítica, Design Science Research.*

ABSTRACT

This Master's Final Project (TFM) addresses the creation, development, and evaluation of a Business Intelligence (BI) solution dedicated to monitoring the performance of a portfolio of Airtime Credit (ATC) projects. The primary focus of this work is resolving a critical operational inefficiency: the tracking of performance and risk indicators was previously handled through a manual, fragmented process in Excel spreadsheets, resulting in a time-consuming analysis cycle. This previous process limited the business team's ability to make quick, proactive, and efficient decisions, often compromising timely identification of anomalies in the service infrastructure and the correction of deviations from the team's monthly goals. To improve these analyses, this TFM aimed to create and implement an automated analytical platform in *Power BI* that provides daily dashboards of key performance indicators for each project in the portfolio.

Guided by the Design Science Research (DSR) methodology, the research process of this project followed the iterative phases of the lifecycle for developing a technology-based artifact. The chosen method involved exploring the organization's Data Warehouse (DW) to extract and structure heterogeneous data using data engineering and data modeling. A multidimensional relational model based on a star schema was created, utilizing aggregated tables to maximize the analytical performance of the artifact. Data Analysis Expressions (DAX) language was also used to code the business intelligence layer, developing formulas for calculating important performance KPIs, monthly goal projections, and temporal analyses of user debt recovery.

The results of the artifact's demonstration in a real business environment proved the utility and effectiveness of the proposed solution. Regarding efficiency, there was a drastic, highly significant reduction in the cycle time for extracting, processing, and visualizing daily and weekly data, freeing up the analyst to spend more time on strategic interpretation tasks. In terms of the artifact's data accuracy and integrity, the audit and cross-validation performed demonstrated strong convergence with traditional methods, with the slight discrepancies found in certain projects being commercially and statistically irrelevant for operational and financial analysis, without compromising the reliability of the platform.

In summary, this work successfully fulfilled its main objectives, delivering a validated technological solution that represents a qualitative leap in the operational efficiency of the ATC team's organization. Among the main limitations of the created artifact, the dependence on the stability and updates of the source data infrastructures stands out. Finally, for future work in this scope, I suggest evolving the system towards a predictive approach by integrating Machine Learning (ML) models for debt risk anticipation and adopting Artificial Intelligence (AI) tools to generate weekly management reports based on the artifact autonomously.

Keywords: Business Intelligence, Airtime Credit, Decision Support, Analytical Automation, Design Science Research.

AGRADECIMENTOS

Com a conclusão deste Trabalho Final de Mestrado chega o fim de um percurso que durou seis anos. É inevitável não agradecer a todos os meus colegas, amigos e docentes que fizeram parte deste percurso académico que me tanto ensinou e fez-me evoluir tanto a nível profissional, como pessoal.

Em primeiro lugar, um agradecimento ao meu orientador Professor Carlos Costa por ter aceiteado este desafio e por ter estado sempre presente e pronto para me guiar com este projeto. Foram muitos os desafios que ao longos destes dois anos foram superados. A palavra gratidão é a que descreve melhor por nunca ter desistido de mim e por ter acreditado sempre que seria possível que este trabalho fosse concluído. Um agradecimento especial a todos os meus colegas de *Airtime Credit* que desde o início do meu recrutamento aceitaram e disponibilizaram todos os recursos necessários para este projeto e também, por demonstrarem sempre interesse para me ajudar, ensinar e melhorar.

Ao longo destes três anos estive inserido em vários grupos e associações com diferentes pessoas. Todas, sem exceção, motivaram-me a continuar no final do dia, após os terminar os meus deveres e responsabilidades que tinha, a trabalhar neste projeto e que fosse concluído com todo o sucesso.

Um agradecimento especial ao meu grupo de amigos mais próximos, que me acompanham desde o ensino secundário, que estando na mesma fase deste percurso académico juntámo-nos durante tardes para nos motivar a trabalhar em cada um dos nossos trabalhos finais. Podemos, em breve, finalmente dizer que conseguimos e que é um orgulho terminar este percurso juntos com todos vocês.

Finalmente, um enorme agradecimento a toda à minha família, em particular ao meu pai e à minha mãe por nunca terem desistido de mim desde o dia que nasci e que fizeram de tudo para que cumprisse todos os meus objetivos e sonho.

ÍNDICE

1	Introdução.....	1
2	Revisão de Literatura.....	3
2.1	Business Intelligence.....	3
2.2	Visualização de Dados	3
2.3	Airtime Credit.....	5
2.4	Data Warehouse.....	7
2.5	Modelo Relacional.....	11
3	Metodologia.....	13
3.1	Enquadramento da Design Science Research.....	13
3.2	Identificação do Problema e Diagnóstico Operacional	14
3.3	Design e Desenvolvimento do Artefacto.....	15
3.3.1	Agregação de Tabelas	15
3.3.2	Engenharia de Dados e Processo de ETL.....	17
3.3.3	Modelo Relacional	19
3.4	Demonstração do Artefacto	23
3.4.1	Formulação DAX.....	23
3.4.2	Dashboards.....	28
3.5	Estratégia de Avaliação	35
4	Resultados.....	36
4.1	Demonstração de Cenários Realistas.....	36
4.2	Avaliação de Eficiência.....	37
4.3	Avaliação de Eficácia e Precisão.....	39
5	Conclusão	42
	Bibliografia.....	44

ÍNDICE DE FIGURAS

<i>Figura 1 - Diagrama do Fluxo de Airtime Credit</i>	<i>7</i>
<i>Figura 2 - Exportação dos dados históricos dos Top-ups.....</i>	<i>17</i>
<i>Figura 3 - Exportação dos dados históricos dos Score Checks</i>	<i>17</i>
<i>Figura 4 - Exportação dos dados históricos das Coleções</i>	<i>17</i>
<i>Figura 5 - Exportação dos dados históricos das Ofertas Realizadas</i>	<i>17</i>
<i>Figura 6 - Exportação dos dados históricos dos Provisionamentos.....</i>	<i>18</i>
<i>Figura 7 - Junção das diferentes tabelas de Top-up</i>	<i>18</i>
<i>Figura 8 - Junção de duas tabelas de Ofertas, Provisionamentos e Coleções</i>	<i>18</i>
<i>Figura 9 - Junção de eventos negados com Score Checks</i>	<i>19</i>
<i>Figura 10 - Modelo Relacional do artefacto</i>	<i>19</i>
<i>Figura 11 - Lista das tabelas do artefacto e respectivas colunas</i>	<i>22</i>
<i>Figura 12 - Medidas em DAX para a Projeção de Valores</i>	<i>24</i>
<i>Figura 13 - Medidas em DAX para o cálculo de KPIs</i>	<i>25</i>
<i>Figura 14 - Medidas em DAX para o cálculo de Bad Debt e a sua recuperação ao longo do tempo</i>	<i>26</i>
<i>Figura 15 - Medidas em DAX para o cálculo das variações semanais</i>	<i>27</i>
<i>Figura 16 - Medida em DAX para o cálculo da receita real e projetada</i>	<i>28</i>
<i>Figura 17 - Dashboard sobre o Controlling Report</i>	<i>29</i>
<i>Figura 18 - Dashboard sobre o Forecast.....</i>	<i>30</i>
<i>Figura 19 - Dashboard sobre a performance geral</i>	<i>31</i>
<i>Figura 20 - Dashboard sobre a recuperação do Bad Debt</i>	<i>32</i>
<i>Figura 21 - Dashboard diário de um projeto do portfólio.....</i>	<i>33</i>
<i>Figura 22 - Dashboard operacional por projeto</i>	<i>35</i>

<i>Figura 23 - Página do ficheiro Excel antigo sobre o Controlling Report</i>	<i>38</i>
<i>Figura 24 - Página do ficheiro Excel antigo sobre os indicadores mensais</i>	<i>38</i>
<i>Figura 25 - Página do ficheiro Excel antigo sobre os resultados de provisionamentos, crédito dado e fee associada.</i>	<i>39</i>
<i>Figura 26 - Comparação dos valores exportados em cada artefacto</i>	<i>40</i>

ÍNDICE DE TABELAS

<i>Tabela 1 - Comparação entre Metodologias de Data Warehouse</i>	<i>10</i>
<i>Tabela 2 - Ligações do Modelo Relacional do Artefacto</i>	<i>21</i>

1 INTRODUÇÃO

O setor das telecomunicações e serviços financeiros digitais, como *Fintech*, assiste a uma rápida evolução, onde a concessão de microcrédito (*Airtime Credit*) emergiu como um serviço crucial. Este serviço, embora que seja um meio para facilitar a liquidez para os clientes, acarreta riscos de crédito que necessitam de monitorização rigorosa e contínua. A gestão eficaz destes projetos exige a análise de um volume crescente de dados, de forma a garantir a sustentabilidade, a otimização da recuperação e o cumprimento das metas operacionais.

O tema deste Trabalho Final de Mestrado nasceu de uma necessidade prática e operacional crítica identificada no ambiente empresarial onde hoje estou inserido. Atualmente, o acompanhamento da performance e do risco dos vários projetos de *Airtime Credit* é realizado através de um processo manual, demoroso e sujeito a erros. Este processo envolve a execução de múltiplas consultas a bases de dados, formatação e análise dos resultados em *Excel* e a realização de um pequeno mas detalhado relatório, consumindo, em média, 4 horas de trabalho para uma análise semanal.

A lentidão deste processo potencia uma incapacidade de tomar decisões rápidas em cenários voláteis, como a identificação imediata de falhas e erros na infraestrutura, a correção de desvios nas metas mensais ou mudanças no comportamento de métricas.

O foco principal deste projeto é transformar este processo eficiente e eficaz às necessidades, estabelecendo uma plataforma de *Business Intelligence* robusta e automatizada. O objetivo final do trabalho é reduzir o tempo de acesso a *insights* críticos permitindo uma gestão ágil e proativa do portfolio de projetos.

Dada a necessidade de otimizar a velocidade e a qualidade da informação de gestão, a questão de Investigação central deste TFM é:

“De que forma a conceção e implementação de um artefacto de Business Intelligence em Power BI pode reduzir o tempo de ciclo de análise de performance e risco em projetos de ATC, promovendo uma tomada de decisão mais informada e atempada?”

O objetivo geral é propor uma solução de BI que forneça visualizações em tempo quase real dos KPIs de desempenho e risco dos projetos de *Airtime Credit*, através do design, desenvolvimento e avaliação de um artefacto em *Power BI*.

Para alcançar este objetivo terá de se identificar e validar o conjunto crítico de KPIs e métricas de risco relevantes para a monitorização de projetos de *Airtime Credit*. De seguida, será concebido um modelo relacional de dados para implementar o processo ETL (*Extract, Transform, Load*) necessário para a alimentação eficiente da solução *Power BI* a partir da fonte de dados. Finalizado o processo ETL será criado uma série de *dashboards* interativos, incluindo visões de performance diária, comparação semanal e um painel de controlo dedicado ao atingimento de metas mensais. No fim realizar-se-á uma avaliação dos *dashboards*, validando a usabilidade, desempenho e, principalmente, a sua capacidade de reduzir o tempo de análise.

A natureza do TFM, com o objetivo da criação de uma solução prática para um problema de negócio real, enquadra-se perfeitamente na metodologia de *Design Science Research* (DSR).

A DSR foca-se na criação e avaliação de artefactos inovadores, como modelos, métodos ou, neste caso, instâncias de *software* como a solução *Power BI*, que sejam relevantes para a gestão de problemas complexos.

Este TFM seguirá um processo iterativo, onde as fases de desenvolvimento e avaliação do artefacto serão intrínsecas. Numa primeira instância será definido o problema deste trabalho e qual a sua motivação para o resolver que conceberá uma arquitetura da solução em BI, definindo fontes de dados, modelo de dados e lógica de visualização de *dashboards*. Com os *dashboards* implementados após desenvolver o artefacto, seguir-se-á a demonstração do uso do artefacto ao contexto real na qual os seus resultados serão avaliados quanto à redução de eficiência e eficácia para a realização de uma tarefa semanal e da gestão do portfólio.

A escolha da DSR assegura que o resultado do TFM não é meramente teórico, mas sim uma contribuição tecnológica validada que resolve uma lacuna de gestão no domínio do *Airtime Credit*.

2 REVISÃO DE LITERATURA

Este capítulo tem como objetivo enquadrar teoricamente o tema em estudo, apresentando os principais conceitos, modelos e abordagens existentes na literatura relacionados com *Business Intelligence*, *Data Warehousing* e a aplicação destas ferramentas no setor de ATC.

2.1 *Business Intelligence*

A *Business Intelligence* é um conjunto de processos e tecnologias com foco na recolha, análise e visualização de dados para potenciar a eficiência operacional e tomada de decisões a nível estratégico e operacional (Vitt et al., 2002). Em 1958, esta expressão foi introduzida pelo Hans Peter Luhn, num contexto científico, como um sistema automático para divulgar as informações das empresas e organizações (Luhn, 1958).

Este termo foi evoluindo ao longo dos anos. Turban & Aronson (1998) incluíram o *Data Warehouse*, a aquisição de dados e a extração de dados para a visualização e análise de negócios, alargando assim, o termo de *Business Intelligence*.

Aproveitaram estas tecnologias e metodologias para transformarem dados brutos em *insights* significativos e essenciais para a gestão operacional e estratégica, melhoraram a competitividade entre setores, otimizaram os processos de recolha e de visualização de dados e aproveitaram também para desenvolverem produtos e serviços de *Business Intelligence* mais avançados e melhorados. Isto levou a uma redução de custos sobre o armazenamento e aquisição de dados, facilitando o desenvolvimento de técnicas de análise de dados mais complexos (Chaudhuri et al., 2011; Chen et al., 2012).

A adoção de sistemas de *Business Intelligence* tem sido alimentada pela crescente concorrência no mercado sobre tecnologias emergentes, tais como a Inteligência Artificial e o *Machine Learning* aumentado ainda mais capacidades deste termo, permitindo análises em tempo real (Shao et al., 2022; Turban et al., 2014).

2.2 *Visualização de Dados*

A visualização de dados é uma das fases do processo da ciência dos dados, que após a recolha, do tratamento e da modelação dos dados, estes mesmos serão visualizados para que se possam tirar conclusões (Lu, 2022). Portanto, a visualização de dados torna-se numa metodologia fundamental para a realizar análises de dados e, posteriormente, retirar

conclusões de modo a avaliar e a realizar decisões estratégicas e operacionais (Few, 2009, Aparicio & Costa, 2015).

Para o objetivo de apoio e suporte à decisão com base na visualização de dados seja cumprido, a escolha da representação gráfica deve ser precedida pela compreensão da natureza dos dados. Munzner (2014) classifica os dados em dois tipos principais, Dados Categóricos e Dados Quantitativos.

Os Dados Categóricos, ou qualitativos, identificam categorias que não possuem uma ordem inerente (Nominais, como o nome de um projeto) ou que seguem uma hierarquia lógica (Ordinais, como níveis de risco baixo, médio ou alto). Enquanto os Dados Quantitativos, ou numéricos, representam quantidades podendo ser discretos (números inteiros) ou contínuos (números reais).

A finalidade de um gráfico depende da correta correspondência entre o tipo de dado e o objetivo da análise. Stephen Few (2012) sugere uma classificação para a seleção de gráficos com base em quatro intenções analíticas, Comparação, Séries Temporais, Composição e Relação. Costa & Aparício (2019) expandem esta visão, ao proporcionar uma árvore de decisão que auxilia a escolha do gráfico ideal para contextos de gestão. Segundo estes dois autores, a eficácia da visualização de dados é um fator importante para aumentar o valor de negócio, que transforma pequenas decisões em ganhos significativos para a uma determinada organização.

Quando o objetivo é comparar valores entre diferentes categorias ou ao longo do tempo, os Gráficos de Barras são considerados os mais eficazes, dado que o cérebro humano processa melhor comprimentos alinhados numa base comum (Few, 2012).

Para observar a evolução e tendência de métricas ao longo de um período, o Gráfico de Linhas é o mais comum, pois concede a continuidade e a inclinação da mudança entre pontos temporais (Tufte, 2001).

Quando se pretende analisar a composição de uma determinada categoria em relação ao total, os Gráficos de *Pie Charts* são os mais comuns. Autores como Cairo (2016) e Few (2012) recomendam um certo tipo de atenção na utilização deste tipo de gráfico devido à dificuldade de perceção de áreas e sugerem Gráficos de Barras Empilhadas ou *Treemaps* como alternativas ao Gráfico de *Pie Charts*.

Para identificar se existe uma relação entre duas variáveis quantitativas, o Gráfico de Dispersão, mais conhecido como *Scatter Plot*, é o mais adequado para este tipo de análise (Munzner, 2014).

No contexto de *dashboards* ao apoio de gestão, a escolha gráfica deve priorizar a redução da carga cognitiva, eliminando elementos não essenciais para que o visualizador consiga identificar desvios de performance em poucos segundos (Tufte, 2001).

Em contexto académico, a visualização de dados tem vindo a ser definida a tradução de informação, em contexto visual e digital, para facilitar a compreensão do cérebro humano, com a identificação de padrões, tendências e *outliers*, a compreensão de correlações, causalidades e, ainda, apoiar em determinados setores como o *controlling* (Andrienko et al., 2020; Bikakis, 2022; Crapo et al., 2000). Está demonstrado também que as técnicas e os métodos de visualização de dados melhoraram a compreensão de modelos complexos e dados multifacetados (Crapo et al., 2000). Utilizar uma representação mais eficaz que permita melhorar a exploração de dados e a construção de modelos poderá aumentar a capacidade da memória de trabalho (Bikakis, 2022).

2.3 *Airtime Credit*

O *Airtime Credit* é definido como um serviço de micro empréstimo de saldo para telemóveis, concebido para permitir que o utilizador realize chamadas, envie SMS e obtenha pacotes de navegação na internet, funcionando como um suporte imediato à comunicação (Babeta & Meshesha, 2024). Embora este método de carregamento apresente vantagens significativas na continuidade do serviço, observa-se que alguns utilizadores podem deixar de utilizar o saldo ou entrar em incumprimento após a aquisição do crédito fornecido.

Este serviço, direcionado especialmente a utilizadores em regime pré-pago, permite a continuidade do uso dos serviços de comunicação assim que se esgota o saldo para chamadas, SMS e/ou o *plafond* de internet móvel. O mecanismo funciona como um adiantamento financeiro a ser descontado na próxima recarga efetuada pelo utilizador, uma solução que se tornou particularmente relevante em economias em desenvolvimento, onde a maior parte da população depende ativamente de planos pré-pagos (Sunduzwayo Madise, 2015).

O processo de solicitação do *Airtime Credit* assenta num mecanismo bastante simples. Quando um utilizador fica sem saldo móvel, pode requerer o adiantamento diretamente do seu telemóvel via SMS, através da aplicação da operadora ou por um código USSD, variando o canal de comunicação consoante a empresa prestadora do serviço. Após a receção do pedido, a operadora avalia a concessão do crédito com base no histórico de recargas e no perfil de endividamento do cliente no serviço. Caso o pedido seja elegível e aprovado, o saldo é disponibilizado ao utilizador e o valor emprestado — frequentemente acrescido de uma taxa de serviço — será automaticamente deduzido assim que for efetuada a próxima recarga (Babeta & Meshesha, 2024).

O serviço de *Airtime Credit* garante vantagens para os utilizadores. Este serviço possibilita que os utilizadores continuem facilmente conectados quando esgotam o seu saldo móvel tornando-se crucial para emergências ou situações inesperadas, permitindo que o utilizador realize chamadas ou aceda à *internet* (Babeta & Meshesha, 2024). A solicitação é rápida e não necessita de um cartão bancário para executar o pedido de crédito, que concede uma maior acessibilidade ao utilizador (Alain Shema, 2021). As operadoras aproveitam muitas das vezes a capacidade do *Machine Learning* e da Inteligência Artificial para analisar padrões de consumo prevendo assim a probabilidade de um utilizador reembolsar o crédito que lhe foi fornecido e até mesmo para decidir qual o melhor valor a conceder ao utilizador, permitindo uma concessão de crédito mais eficiente e reduzindo os custos de *Bad Debt* (Babeta & Meshesha, 2024).




Figura 1 - Diagrama do Fluxo de Airtime Credit

2.4 Data Warehouse

Um Data Warehouse é um sistema centralizado de armazenamento de dados que integra informações provenientes de várias fontes, estruturando-as de forma a facilitar análises e tomadas de decisão. É otimizado para consultas analíticas e relatórios, sendo uma componente essencial para sistemas de *Business Intelligence*. De acordo com Kimball e Ross (2002), um *Data Warehouse* é projetado para suportar a análise de dados

históricos e a criação de relatórios estratégicos, recorrendo a uma estrutura dimensional que permite acesso eficiente e flexível à informação.

Porém, até que os dados cheguem ao *Data Warehouse*, percorrem um percurso com várias transformações que ocorrem ao longo das várias etapas para depois serem usadas em aplicações analíticas (Cottur & Gadad, 2020). Pode incluir etapas, como a extração, o pré-processamento e a validação dos dados.

A primeira abordagem no contexto deste tipo de processos foi a utilização de uma ferramenta de extração, transformação e carregamento (ETL). Esta ferramenta foi desenvolvida para facilitar o acesso dos dados, permitindo a utilização em ferramentas analíticas. Esta abordagem permite a utilização efetiva da informação, conduzindo a uma tomada de decisões mais informada e à divulgação dos conhecimentos originados pelos dados (Davenport, 2006). O ETL é um componente crítico da *Business Intelligence* e do *Data Warehouse*, compreendendo três fases fundamentais: extração, transformação e carregamento. A extração consiste em aceder e recuperar dados dos sistemas de origem ou de armazéns de dados. Isto envolve a seleção e copiar dados relevantes a partir da fonte, considerando fatores como o acesso ao sistema, formatos de dados e minimização do impacto nos sistemas de origem (Kimball & Ross, 2002; Reeve, 2013). A transformação é o processo de conversão dos dados extraídos do seu formato original para um formato compatível com o sistema de destino. Isto envolve várias tarefas, incluindo a identificação de dados de referência para normalizar valores agregados dos dados para os resumir, normalização dos dados para os organizar e realização de cálculos para obter novos pontos de dados. O objetivo é limpar, estruturar e preparar dados para os alinhar com os requisitos do sistema-alvo (Reeve, 2013). Na fase final, o processo de carregamento implica a apresentação dos dados em tabelas de qualidade. Quando os dados tiverem concluído estes procedimentos necessários de carregamento, verificação, agregação e procedimentos de controlo de qualidade, estão prontos para serem utilizados para fins analíticos (Kimball & Ross, 2002).

Para entender melhor o ecossistema de armazenamento de dados, é importante detalhar as abordagens que rivalizam ou complementam o modelo dimensional de Kimball. A metodologia de Bill Inmon adota uma filosofia *top-down*, onde os dados operacionais são primeiramente integrados num repositório central e em seguida

normalizados na Terceira Forma Normal (3NF), o que garante uma única versão fidedigna antes de serem distribuídos por *Data Marts* dependentes (Inmon, 2005). No entanto, para resolver a rigidez de Inmon e o rastreo histórico em larga escala de Kimball, Dan Linstedt introduz uma arquitetura *Data Vault* (Linstedt & Olschimke, 2015). Esta abordagem é baseada num modelo híbrido focado nos seguintes três componentes estruturais: *Hubs* que identificam chaves de negócio, *Links* que permitem realizar associações entre transações e *Satellites*, atributos contextuais e temporais. Este último permite armazenar dados brutos e realizar auditorias completas sem necessidade de *refactoring* constante (Linstedt & Olschimke, 2015).

Em resumo, a implementação de um *Data Warehouse* pode seguir diferentes metodologias de design, sendo a proposta de Kimball a mais predominante mencionada em cima nesta literatura. Enquanto Kimball defende uma abordagem descentralizada baseada em *Data Marts* dimensionais para facilitar a rapidez de entrega ao negócio, Inmon propõe uma estrutura centralizada na Terceira Forma Normal que foca a integridade e governação global dos dados. Adicionalmente, sugiro a metodologia de *Data Vault* como uma alternativa híbrida que oferece maior escalabilidade e flexibilidade em ambientes de grandes volumes de dados. As principais distinções técnicas e filosóficas entre estas abordagens estão detalhadas na Tabela 1 que se encontra em baixo.

Propriedades	Inmon	Kimball	<i>Data Vault</i>
Principal Objetivo	<i>Data Warehouse</i> Centralizado	<i>Data Marts</i>	Dados Brutos
Filosofia	Abordagem <i>Top-Down</i>	Abordagem <i>Bottom-Up</i>	Abordagem Híbrida
Integração de Dados	ETL (Extração, Transformação, Carregamento)	ETL (Extração, Transformação, Carregamento)	ETL (Extração, Transformação, Carregamento)
Estrutura de Dados	Terceira Forma Normal	Modelação Dimensional	Altamente Normalizada
Granularidade dos Dados	Elevado Detalhe	Sumarizada e Pré-Agregada	Bruta e Não Agregada
Flexibilidade	Menos Flexível	Mais Flexível	Altamente Flexível
Escalabilidade	Moderada	Boa	Excelente
Desempenho	Moderado	Bom	Excelente
Complexidade	Alta	Moderada	Moderada a Alta
Facilidade de Manutenção	Complexa	Relativamente Fácil	Moderada
Gestão de Dados	Integrada no DW Central	Em <i>Data Marts</i> Individuais	Nativa (<i>Hubs, Satellites, Links</i>)
Caso de Utilização	Relatórios e Análises Complexas	Relatórios e Análises Departamentais	<i>Data Warehousing</i> , Integração de <i>Big Data</i>
Adequado para	Grandes Empresas	Médias a Grandes Empresas	Várias Indústrias e Fontes de Dados

Tabela 1 - Comparação entre Metodologias de Data Warehouse

2.5 Modelo Relacional

O modelo relacional, proposto por Codd em 1970, representa um marco fundamental no desenvolvimento dos sistemas de bases de dados. Nesta abordagem, os dados são organizados em tabelas compostas por linhas (*tuplos*) e colunas (*atributos*), permitindo uma representação lógica simples e consistente, independente da estrutura física de armazenamento (Codd, 1970). Esta separação entre o modelo lógico e o modelo físico trouxe a desejada independência de dados, facilitando a manutenção e a evolução dos sistemas (Codd, 1971).

Cada tabela no modelo relacional é identificada por uma chave primária que é um ou mais atributos que identifica distintamente cada registo. As chaves estrangeiras, por sua vez, são utilizadas para estabelecer relações entre tabelas distintas, assegurando a integridade referencial dos dados. Esta estrutura permite uma organização robusta e coerente dos dados, facilitando a execução de operações relacionais como seleção, projeção, união e junção das tabelas.

No entanto, para além da estrutura relacional clássica, os sistemas de suporte à decisão evoluíram para o paradigma *Online Analytical Processing* (OLAP). Ao contrário dos sistemas transacionais (OLTP), o OLAP foca-se na rapidez de resposta de consultas complexas e multidimensionais que permitem aos visualizadores analisarem os dados através de diferentes perspetivas e níveis de detalhe em *Drill-down* ou *Roll-up*. A eficácia do OLAP está dependente das técnicas de modelação dimensional aplicadas no *Data Warehouse*.

No contexto de *Business Intelligence* e *Data Warehouse*, o modelo relacional é frequentemente adaptado para suportar cargas analíticas intensivas. Para isso, recorre-se a modelos dimensionais como o modelo estrela e o modelo floco de neve. No modelo estrela, os dados são organizados em torno de uma tabela de factos em medidas quantitativas ligada diretamente a várias tabelas de dimensão, no qual permite consultas rápidas e simples. Já o modelo floco de neve é uma extensão do modelo estrela, em que as dimensões são normalizadas em múltiplas tabelas, reduzindo redundâncias mas aumentando a complexidade das consultas (Kimball & Ross, 2002).

A escolha entre estes modelos depende de fatores como a complexidade dos dados, a performance desejada e os requisitos analíticos da organização. Ambos os modelos se

mantêm dentro do paradigma relacional, baseando-se em chaves primárias e estrangeiras para manter a integridade e estrutura dos dados.

A normalização, proposta também por Codd, é um processo que organiza os dados em várias formas normais para reduzir redundância e eliminar anomalias. Contudo, em ambientes de *Data Warehouse*, é comum aplicar uma desnormalização controlada para otimizar o desempenho de leitura e simplificar a modelação de dados analíticos (Inmon, 2005; Kimball & Ross, 2002).

O modelo relacional continua a ser a base dos sistemas de bases de dados modernos, servindo de fundamento para a construção de soluções de *Business Intelligence* e *Data Warehousing*, onde a sua flexibilidade e solidez estrutural são cruciais para garantir a consistência e acessibilidade da informação.

3 METODOLOGIA

3.1 *Enquadramento da Design Science Research*

Inicialmente, a condução deste trabalho fundamenta-se em *Design Science*, que se diferencia das ciências naturais por não procurar apenas descrever ou explicar acontecimentos reais mas sim transformá-los através da criação de artefactos que resolvam problemas práticos. Segundo Simon (1996), as ciências do artificial focam-se em projetos de objetos e sistemas que possuem propriedades desejadas e que são moldados para atingir determinados objetivos específicos que estabelecem uma ponte entre a teoria e a prática. Neste âmbito, March e Smith (1995) argumentam que a investigação em tecnologia da informação equilibra a compreensão teórica com a vertente prática, identificando quatro tipos de artefactos fundamentais: os conceitos, os modelos, os métodos e as implementações. A *Design Science Research* surge como a aplicação rigorosa deste paradigma na vertente da investigação científica. Esta metodologia é justificada pela natureza deste projeto com o objetivo de resolver um problema operacional, retirado no âmbito empresarial, através do desenvolvimento de um artefacto na base de BI. Hevner et al. (2004), defende que a DSR procura alargar as fronteiras das capacidades humanas e organizacionais através da criação de artefactos inovadores que centram a utilidade e a eficácia da solução proposta. Desta forma, o trabalho não se limita à análise teórica mas foca-se em construir e avaliar uma solução que responda ao problema identificado.

A metodologia selecionada para a condução deste trabalho é a *Design Science Research*. Esta metodologia escolhida justifica-se pela natureza do projeto que está a ser realizado neste trabalho com o objetivo de resolver um problema prático através da criação de um artefacto de base tecnológica. Segundo Hevner et al. (2004), a DSR procura alargar as fronteiras das capacidades humanas e organizacionais através da criação de artefactos inovadores, centrando-se na utilidade e na eficácia da solução proposta face a problemas de negócio reais.

O processo de investigação adotado neste trabalho segue o modelo de ciclo de vida proposto por Peffers et al. (2008), que estrutura a investigação através de uma abordagem sistemática e rigorosa para a criação de conhecimento técnico. Segundo Aparício et al.

(2023), a aplicação da DSR em Sistemas de Informação permite que a criação do artefacto seja orientada por um processo devidamente estruturado para assegurar a relevância do problema e a utilidade da solução desenvolvida para o problema. Este ciclo tem início com a identificação do problema e sua motivação, na qual é realizado o diagnóstico dos problemas atuais. Em seguida, definem-se os objetivos da solução que se estabelecem em requisitos de desempenho necessários, como a eficiência, eficácia e a rapidez da obtenção dos dados estruturados. Na fase de design e desenvolvimento é constituído o núcleo da criação do artefacto, que envolve a estruturação do modelo de dados, a codificação de métricas em DAX e a criação dos *dashboards* em *Power BI*. Após esse desenvolvimento, procede-se à demonstração que consiste na implementação do artefacto no mundo real utilizando dados extraídos dos sistemas da organização. A próxima etapa é a avaliação do artefacto, onde se efetua a validação da solução desenvolvida face aos objetivos inicialmente propostos do processo de DSR, é onde se compara o novo processo automatizado com o método manual usado anteriormente. Por último, a fase de comunicação termina o ciclo deste método com a documentação detalhada dos resultados o contributo prático deste trabalho para a área de *Airtime Credit*.

3.2 Identificação do Problema e Diagnóstico Operacional

O ponto de partida deste trabalho reside na ineficiência e demorado processo de análise da performance em projetos de *Airtime Credit*. Hoje em dia, a recolha de dados para uma análise semanal de controlo financeiro e operacional é feita de forma fragmentada e manual a partir de 6 *queries* por projeto para obter os valores pretendidos e colocar num ficheiro *Excel*, o que resulta num ciclo de análise que demora cerca de 4 horas para ser concluído.

Conforme discutido na DSR (Hevner et al., 2004), a relevância do problema é um critério de sucesso. Neste caso, a demora no processamento manual impede a identificação atempada de falhas de infraestrutura, quebras bruscas de performance ou a veracidade dos dados exportados. O objetivo central é transitar de um processo de execução manual para um processo automático diário e semanal, permitindo reduzir o tempo de acesso à visualização dos dados.

3.3 *Design e Desenvolvimento do Artefacto*

A fase de design fundamenta-se nos princípios teóricos de *Business Intelligence* e Visualização de Dados explorados na Revisão da Literatura. O desenvolvimento do artefacto inicia-se com a exploração do *Data Warehouse* da organização, de onde são exportados os dados necessários a partir de tabelas já agregadas. Esta extração é refinada através da aplicação de filtros específicos, garantindo que apenas a informação pertinente ao contexto de *Airtime Credit* é integrada na solução.

Uma vez os dados importados para o ecossistema *Power BI*, o processo de desenvolvimento envolve a criação de tabelas auxiliares e de suporte, permitindo estruturar a informação de forma otimizada para os objetivos do projeto. O design do artefacto seguirá as melhores práticas de visualização de Few (2012) e Tufte (2001), focando na redução da carga cognitiva e no aumento do rácio dado-tinta (*data-ink ratio*). O desenvolvimento contemplará um modelo de dados, métrica em DAX e painéis interativos (*dashboards*). Relativamente ao modelo de dados, será estruturado em Esquema Estrela (*Star Schema*) para otimizar a performance das consultas analíticas (Kimball & Ross, 2002), tirando partido da integração entre as tabelas exportadas e as novas tabelas criadas para suporte à lógica de negócio. A programação de medidas complexas será desenvolvida através da linguagem DAX para o cálculo de KPIs críticos, como o *Bad Debt*, Taxa de Recuperação e para a verificação do cumprimento em relação ao *Forecast* mensal. O artefacto estará distribuído com vários *dashboards* para visualizações específicas sobre a performance diária, semanal e mensal, comparação semanal dos KPIs e da projeção de resultados, desenhadas para uma navegação intuitiva e dinâmica.

3.3.1 *Agregação de Tabelas*

Uma decisão fundamental no design deste artefacto foi a utilização de tabelas agregadas ao invés de tabelas transacionais na qual contêm um ID único para uma transação com determinadas características. As tabelas agregadas são tabelas estruturadas com dados onde a informação tem origem das tabelas transacionais, resumindo a informação numa só linha com base em dimensões específicas, como a data, anos e mês, operador, tipo de oferta e canal. Esta abordagem por tabelas agregadas foi adotada pela

razão do interesse do projeto ser a monitorização de performance num determinado tempo e análise de projeções de resultados, e não ter interesse numa auditoria de transações específicas. Esta simplificação arquitetural reduz drasticamente o volume de dados processado pelo *Power BI*, o que garante uma maior rapidez na atualização diária e menos armazenamento de informação para tornar o artefacto mais eficiente.

Para obter uma visão geral do fluxo de negócio, foram identificados cinco pilares fundamentais, dos quais os dados foram carregados e consolidados: *Score Checks*, Ofertas Realizadas, Provisionamentos, *Top-ups* e Coleções.

Os *Score Checks* que contêm o histórico de verificações de elegibilidade e risco dos utilizadores (*scoring*) para atribuir uma determinada oferta. As ofertas realizadas que provêm a partir desse *scoring*. Quando a oferta é efetuada, o utilizador poderá, ou não, aceitar a oferta de crédito realizada e esta ação é o que chamamos de provisionamento. Após se dar um provisionamento, a identidade que proporcionou o crédito fica dependente de recuperação do crédito efetuado e essa coleção do crédito só efetuada totalmente ou parcialmente a partir de uma recarga (*Top-up*).

Adicionalmente, para permitir a segmentação e o enriquecimento das análises, foram integradas as seguintes tabelas de contexto e suporte: *Forecast*, Tipos de *Trigger*, Canais, Calendário, Razões de Rejeição de conceder crédito, Operadores e Taxas de Câmbio.

O *Forecast* contém o histórico das metas propostas pela equipa de *Airtime Credit* para cada operador. Esta tabela é proveniente de um ficheiro *Excel*, que é atualizado mensalmente. Nos tipos de *Trigger* é descrito o tipo de evento do mecanismo automático que inicia um processo de *scoring* ao utilizador. A tabela de canais identifica o meio através do qual foi efetuada a oferta ou o processo de *scoring* automaticamente através da base de dados. O calendário está estruturado de forma temporal através de um ficheiro *Excel* para permitir uma análise histórica contínua. As razões de rejeição foram estruturadas diretamente no ambiente *Power BI* para indicarem os motivos, com os seus respetivos códigos, pelos quais um utilizador não foi considerado elegível para receber uma determinada oferta de crédito. Também criada no *Power BI*, a tabela de operadores contém a informação caracterizadora de cada operadora envolvida nos projetos de *Airtime Credit*. Nas taxas de câmbio é apresentado o histórico dos câmbios dos países das

operadoras permitindo a normalização financeira dos dados. Esta tabela é proveniente de um ficheiro *Excel*, que é atualizado mensalmente.

Todas estas tabelas fornecem os atributos e a informação necessária para contextualizar os pilares principais de modo que o artefacto proporcione as informações e análises necessárias para o objetivo deste projeto.

3.3.2 Engenharia de Dados e Processo de ETL

O processo de ETL (*Extract, Transform, Load*) foi executado através do Power Query, onde se procedeu à harmonização de fontes de dados heterogéneas como mostra da figura 2 até à figura 6.

```
= Oracle.Database("dwh", [HierarchicalNavigation=true, Query="SELECT /*+parallel(8)*/ operator_id, TO_char(TOPUP_DATE,'yyyymmdd') AS Top_up_date, SUM(amount) AS Amount#(1f) FROM REP.TOPUP#(1f)WHERE TOPUP_DATE>=TO_DATE('010125','ddmmyy') AND operator_id IN (8,508,17110)#(1f)GROUP BY operator_id, TO_char(TOPUP_DATE,'yyyymmdd')#(1f)ORDER BY operator_id, TO_char(TOPUP_DATE,'yyyymmdd')", CommandTimeout=#duration(0, 0, 30, 0)])
```

Figura 2 - Exportação dos dados históricos dos Top-ups

```
= Oracle.Database("dwh", [HierarchicalNavigation=true, Query="SELECT /*+parallel(8)*/ operator_id, SCORE_SOURCE, SCORE_DATE_TZ, YEARMONTH, RESULT_CODE, OFFER_TYPE_ID, SUM(SCORE_COUNT)#(1f)FROM air_time_credit.score_check_hourly#(1f)WHERE SCORE_DATE_TZ >=20250101 AND operator_id <> 431#(1f)GROUP BY operator_id, SCORE_SOURCE, SCORE_DATE_TZ, YEARMONTH, RESULT_CODE, OFFER_TYPE_ID#(1f)ORDER BY operator_id, SCORE_SOURCE, SCORE_DATE_TZ, YEARMONTH, RESULT_CODE, OFFER_TYPE_ID", CommandTimeout=#duration(0, 0, 30, 0)])
```

Figura 3 - Exportação dos dados históricos dos Score Checks

```
Oracle.Database("dwh", [HierarchicalNavigation=true, Query="SELECT operator_id, DEBT_TYPE, COLLEC_DATE_TZ, PROV_DATE_TZ, YEARMONTH, SUM(DEBT_AMOUNT), SUM(COLLECT_COUNT)#(1f)FROM air_time_credit.mbc_credit_collec_event_hourly#(1f)WHERE debt_type<>'vat'AND PROV_DATE_TZ >=20250101 AND COLLEC_DATE_TZ >=20250101 AND OPERATOR_ID <> 431 AND RATING_ID <>9010#(1f)GROUP BY operator_id, DEBT_TYPE, COLLEC_DATE_TZ, PROV_DATE_TZ, YEARMONTH#(1f)ORDER BY operator_id, DEBT_TYPE, COLLEC_DATE_TZ, PROV_DATE_TZ, YEARMONTH"])
```

Figura 4 - Exportação dos dados históricos das Coleções

```
= Oracle.Database("dwh", [HierarchicalNavigation=true, Query="SELECT operator_id, OFFER_SOURCE, OFFER_DATE_TZ, OFFER_TYPE_ID, YEARMONTH, SUM(OFFER_COUNT)#(1f)FROM air_time_credit.MBC_CREDIT_OFFER_EVENT_HOURLY#(1f)WHERE OFFER_DATE_TZ >= 20250101 AND RATING_ID <> 9010 AND operator_id <> 431#(1f)GROUP BY operator_id, OFFER_SOURCE, OFFER_DATE_TZ, OFFER_TYPE_ID, YEARMONTH#(1f)ORDER BY operator_id, OFFER_SOURCE, OFFER_DATE_TZ, OFFER_TYPE_ID, YEARMONTH", CommandTimeout=#duration(0, 0, 30, 0)])
```

Figura 5 - Exportação dos dados históricos das Ofertas Realizadas

```
= Oracle.Database("dwh", [HierarchicalNavigation=true, Query="SELECT /*+parallel(8)*/ operator_id, OFFER_SOURCE, PROV_DATE_TZ, YEARMONTH, OFFER_TYPE_ID, SUM
(PROV_CREDIT_AMOUNT), SUM(PROV_FEE_AMOUNT), SUM(PROV_COUNT)#(1f)FROM air_Time_credit.MBC_CREDIT_PROV_EVENT_HOURLY#(1f)WHERE PROV_DATE_TZ >= 20250101 AND OPERATOR_ID
<>431 AND RATING_ID <> 9010#(1f)GROUP BY operator_id, OFFER_SOURCE, PROV_DATE_TZ, YEARMONTH, OFFER_TYPE_ID#(1f)ORDER BY operator_id, OFFER_SOURCE, PROV_DATE_TZ,
YEARMONTH, OFFER_TYPE_ID", CommandTimeout=#duration(0, 0, 30, 0))]
```

Figura 6 - Exportação dos dados históricos dos Provisionamentos

Dado que dois dos operadores em análise possuem informações em tabelas com características específicas e separadas da estrutura principal mencionada nas figuras em cima, foi necessário exportar essas tabelas individualmente e proceder à sua integração.

Antes da junção da informação em falta, foi necessário renomear e alterar o formato de dados das colunas em diversas tabelas para garantir a integridade. Este passo é fundamental para assegurar que a junção de dados ocorresse com 100% de integridade, centralizando a informação de todos os operadores em tabelas “mestres” de *Score Checks*, Ofertas, Provisionamentos, Top-ups e Coleções.

Neste artefacto, foi executado a junção de duas tabelas de *Top-ups* de dois projetos distintos à tabela “mestre” de *Top-ups*, também a junção de Ofertas, Provisionamentos e Coleções de um projeto às respetivas tabelas e ainda, fez-se a junção à tabela de *Score Checks* a informação de eventos negados para um operador ter o número total de eventos dos quais se fizeram um *scoring* completos.

```
= Table.Combine({#"Tipo Alterado", #"TOPUP VIVO", #"TOPUP PALESTINE"})
```

Figura 7 - Junção das diferentes tabelas de Top-up

```
= Table.Combine({Origem, #"OFFERS PALESTINE"})
= Table.Combine({#"Tipo Alterado", #"PROVISIONS PALESTINE"})
= Table.Combine({Origem, #"COLLECTIONS PALESTINE"})
```

Figura 8 - Junção de duas tabelas de Ofertas, Provisionamentos e Coleções

```
= Table.Combine({#"Colunas com Nome Mudado", #"DENIED PALESTINE"})
```

Figura 9 - Junção de eventos negados com Score Checks

Já no ambiente do *Power BI*, através da linguagem DAX como mostram as figuras 10 e 11, foram criadas colunas calculadas específicas para viabilizar o relacionamento entre tabelas. Destacam-se as criações de chaves composta pela junção do *operator_id* com o *yearmonth*, *offer_type* e *source* nas tabelas de *Score Checks*, Ofertas e Provisionamentos. Esta chave é indispensável para garantir que as relações com as tabelas dimensionais respeitem o contexto de cada projeto num determinado período, tipo de oferta e canal. Sem esta chave, uma relação apenas por *yearmonth*, por exemplo, resultaria em dados agregados incorretamente para todos os projetos em simultâneo.

3.3.3 Modelo Relacional

O modelo relacional do artefacto foi estruturado seguindo os princípios semelhantes de um Esquema de Estrela (*Star Schema*), apresentado na figura 10. Este tipo esquemático é caracterizado pela separação clara entre tabelas de factos, que contêm as métricas quantitativas do negócio e tabelas dimensionais, que fornecem o contexto descritivo para as análises a serem realizadas.




Figura 10 - Modelo Relacional do artefacto

Dada a natureza do fluxo de negócio de *Airtime Credit*, o modelo integra cinco tabelas de factos centrais. Embora o esquema proposto por Kimball e Ross para um esquema em estrela apresente apenas uma tabela de factos, a opção por manter cinco tabelas distintas, *Score Checks*, Ofertas, Provisionamentos, Top-ups e Coleções, é fundamental para garantir a integridade e a clareza da informação.

Cada tabela de factos representa um momento específico do fluxo de negócio do *Airtime Credit*. Ao manter estas tabelas separadas, sem ligação entre elas, permite que o modelo relacione cada evento à sua respetiva data e contexto sem gerar ambiguidades, duplicação de dados e erros de relação. Por se tratar de tabelas com dados agregados, estas tabelas de factos são extremamente eficientes no processamento de grandes volumes de informação. Permite assim, que o modelo responda instantaneamente a filtros de tempo, operador, canal e tipo de oferta, assegurando que a análise global de performance durante o fluxo de *Airtime Credit* seja possível.

A coesão do esquema em estrela é garantida através das tabelas de dimensão que fazem a ligação para as tabelas de facto. Tabelas como a DATE e a OPERATORS estabelecem uma ligação com todas as 5 tabelas de facto a todas as tabelas de factos pela simples razão do foco e objetivo principal deste projeto ser a visualização da *performance* num determinado tempo para um portfólio de operadores de ATC e, como tal, estas duas tabelas devem estar ligadas a todas as tabelas de facto permitindo que um único filtro aplicado num dashboard afete simultaneamente todos os indicadores do negócio. As restantes tabelas de dimensão só estabelecem ligação com as tabelas de facto para que seja possível ter uma análise adequada para uma determinada altura do fluxo de negócio, como é o caso da ligação da tabela EXCHANGE RATE ser exclusiva com a de PROVISIONS dado que esta tem os valores de crédito concedido e a sua *fee* associada e permite ao visualizador perceber o valor em euro face à moeda local.

Esta abordagem assegura que o modelo relacional seja robusto, escalável e fácil de manter, permitindo uma transição perfeita entre a análise de diferentes fases do negócio.

Em baixo encontra-se a tabela 2 com as ligações entre as tabelas e o seu tipo de relação.

Ligação entre Tabelas	Tipo de Relação	Chave de ligação
DATE → COLLECTIONS	Um (1) → Muitos (*)	PROV_DATE_TZ
DATE → OFFERS	Um (1) → Muitos (*)	OFFER_DATE_TZ
DATE → PROVISIONS	Um (1) → Muitos (*)	PROV_DATE_TZ
DATE → SCORE CHECKS	Um (1) → Muitos (*)	SCORE_DATE_TZ
DATE → TOPUP	Um (1) → Muitos (*)	TOP_UP_DATE
DENIED CODES → SCORE CHECKS	Um (1) → Muitos (*)	RESULT_CODE
EXCHANGE RATES → PROVISIONS	Um (1) → Muitos (*)	OPERATOR_YEARMONTH
FCST → OFFERS	Um (1) → Muitos (*)	OPERATOR_YEARMONTH
FCST → PROVISIONS	Um (1) → Muitos (*)	OPERATOR_YEARMONTH
FCST → SCORE CHECKS	Um (1) → Muitos (*)	OPERATOR_YEARMONTH
OFFER TYPE → OFFERS	Um (1) → Muitos (*)	OPERATOR_OFFER_TYPE
OFFER TYPE → PROVISIONS	Um (1) → Muitos (*)	OPERATOR_OFFER_TYPE
OFFER TYPE → SCORE CHECKS	Um (1) → Muitos (*)	OPERATOR_OFFER_TYPE
OPERATORS → COLLECTIONS	Um (1) → Muitos (*)	OPERATOR_ID
OPERATORS → OFFERS	Um (1) → Muitos (*)	OPERATOR_ID
OPERATORS → PROVISIONS	Um (1) → Muitos (*)	OPERATOR_ID
OPERATORS → SCORE CHECKS	Um (1) → Muitos (*)	OPERATOR_ID
OPERATORS → TOPUP	Um (1) → Muitos (*)	OPERATOR_ID
SOURCES → OFFERS	Um (1) → Muitos (*)	OPERATOR_SOURCE
SOURCES → PROVISIONS	Um (1) → Muitos (*)	OPERATOR_SOURCE
SOURCES → SCORE CHECKS	Um (1) → Muitos (*)	OPERATOR_SOURCE

Tabela 2 - Ligações do Modelo Relacional do Artefacto

Na figura 11, que se encontra em baixo, está representado as colunas de todas as tabelas mencionadas neste capítulo juntamente com a junção das colunas e métricas criadas em DAX. Estas últimas serão de discutidas no capítulo seguinte.

SCORE CHECKS - Eligibility - OFFER_TYPE_ID - OPERATOR_ID - OPERATOR_OFFER_TYPE - OPERATOR_SOURCE - OPERATOR_YEARMONTH - RESULT_CODE - SCORE COUNT - SCORE_DATE_TZ - SOURCE_ID - YEARMONTH - Eligibility% - Score Checks Daily	OFFERS - OFFER COUNT - OFFER_DATE_TZ - OFFER_TYPE_ID - OPERATOR_ID - OPERATOR_OFFER_TYPE - OPERATOR_SOURCE - OPERATOR_YEARMONTH - SOURCE_ID - YEARMONTH - Conversion% EXCHANGE RATES - EXCHANGE_RATE - OPERATOR_ID - OPERATOR_YEARMONTH - YEARMONTH	PROVISIONS - CREDIT_AMOUNT - FEE_AMOUNT - OFFER_TYPE_ID - OPERATOR_ID - OPERATOR_OFFER_TYPE - OPERATOR_SOURCE - OPERATOR_YEARMONTH - PROV COUNT - PROV_DATE_TZ - SOURCE_ID - YEARMONTH %Fee - AVG Ticket - Daily Credit - Daily Fee - Penetration% - Provisions Daily	TOPUP - AMOUNT - OPERATOR_ID - TOPUP_DATE - Representativeness OPERATORS - BAD DEBTS - COUNTRY - MAX_ELAPSED - OPERATOR - OPERATOR_ID - RESTATE SHARES - TYPE MODEL OFFER TYPE - NAME - OFFER_TYPE_ID - OPERATOR_ID - OPERATOR_OFFER_TYPE
DENIED CODES - DENIED_REASON - RESULT_CODE - RESULT_CODE_DESCRIPTION			
COLLECTIONS - COLLEC_DATE_TZ - COLLECT COUNT - COLLECTION_TIME - DEBT_AMOUNT - DEBT_TYPE - OPERATOR_ID - PROV_DATE_TZ - YEARMONTH - Bad Debt% - Credit Collect - Credit Collected Percentage - Credit Collected Percentage Curve ... - Credit Collected running total in c... - Daily Collect - Daily Credit Collection - Fee Collect	FCST - CONVERSION_FCST - CREDIT_FCST - ELIGIBILITY_FCST - FEE_FCST - MONTH - OFFERS_FCST - OPERATOR_ID - OPERATOR_YEARMONTH - PROVS_FCST - SCORES_CHECK_FCST - YEAR - YEARMONTH %Credit Achievement %Fee Achievement %Offers Achievement %Provisions Achievement %Score Checks Achievement - Month Condition - Projection Factor - Total Day Current - Total Days	DATE - COLLEC_DATE_TZ - DATE - DAY - MONTH - OFFER_DATE_TZ - PAST_WEEKS - PROV_DATE_TZ - QUARTER - SCORE_DATE_TZ - TOPUP_DATE_TZ - YEAR - YEARMONTH - Count Days SOURCES - OPERATOR_ID - OPERATOR_SOURCE - SOURCE_ID - SOURCE_KEY	

Figura 11 - Lista das tabelas do artefacto e respectivas colunas

3.4 *Demonstração do Artefacto*

A demonstração servirá para comprovar que a solução desenvolvida é capaz de responder aos desafios identificados no contexto real. Segundo Peffers (2008), esta fase envolve a utilização do artefacto para resolver instâncias específicas do problema.

Neste contexto, o protótipo de *Power BI* será alimentado com dados reais extraídos da base de dados de *warehouse* da empresa através de *queries* SQL, já codificadas para a exportação automática diárias dos dados. A demonstração focará na capacidade do sistema em transformar dados em indicadores visuais claros, permitindo ao utilizador do artefacto identificar desvios de performance em tempo quase real e de projetar valores para o cumprimento de metas internas.

3.4.1 *Formulação DAX*

Para viabilizar a visualização de KPIs, variações semanais, médias diárias, projeções mensais e cálculos de receita foi necessário implementar uma camada de inteligência através da linguagem DAX. O desenvolvimento focou-se na criação de medidas em ambiente *Power BI*.

3.4.1.1 *Projeções*

Para responder à necessidade de antecipar o cumprimento de metas delineadas pela equipa de ATC, foram criadas medidas focadas na projeção de valores para o fecho do mês corrente. Esta lógica baseia-se num fator de projeção, calculado como um rácio entre o número total de dias do mês e o dia atual do calendário.

Dada a coexistência de dados históricos e atuais no modelo, foi implementada uma condição lógica que garante a integridade da análise. A medida identifica o mês em curso para aplicar o fator de projeção e para os meses anteriores, o sistema apresenta automaticamente o valor real consolidado. Adicionalmente, foram desenvolvidas medidas que calculam o desvio percentual entre a projeção e as metas delineadas pela equipa, permitindo uma leitura imediata do estado de cumprimento.

Na figura em baixo, encontram-se todas as métricas criadas para este âmbito de projeções.

```

1 Total Days = DAY(EOMONTH(TODAY(),0))
1 Total Day Current = DAY(TODAY())-1
1 Projection Factor = DIVIDE([Total Days],[Total Day Current])
1 Month Condition =
2 IF(
3     SELECTEDVALUE('DATE'[YEARMONTH]) = VALUE(FORMAT(TODAY(), "YYYYMM")),
4     1,
5     BLANK()
6 )
1 %Score Checks Achievement =
2 VAR RealValue = DIVIDE(SUM('SCORE CHECKS'[SCORE COUNT]), SUM('FCST'[SCORES_CHECK_FCST]))
3 RETURN
4 IF(
5     [Month Condition] = 1,
6     RealValue * [Projection Factor],
7     RealValue
8 ) -1
1 %Offers Achievement =
2 VAR RealValue = DIVIDE(SUM('OFFERS'[OFFER COUNT]), SUM('FCST'[OFFERS_FCST]))
3 RETURN
4 IF(
5     [Month Condition] = 1,
6     RealValue * [Projection Factor],
7     RealValue
8 ) -1
1 %Provisions Achievement =
2 VAR RealValue = DIVIDE(SUM('PROVISIONS'[PROV COUNT]), SUM('FCST'[PROVS_FCST]))
3 RETURN
4 IF(
5     [Month Condition] = 1,
6     RealValue * [Projection Factor],
7     RealValue
8 ) -1
1 %Credit Achievement =
2 VAR RealValue = DIVIDE(SUM('PROVISIONS'[CREDIT_AMOUNT]), SUM('FCST'[CREDIT_FCST]))
3 RETURN
4 IF(
5     [Month Condition] = 1,
6     RealValue * [Projection Factor],
7     RealValue
8 ) -1
1 %Fee Achievement =
2 VAR RealValue = DIVIDE(SUM('PROVISIONS'[FEE_AMOUNT]), SUM('FCST'[FEE_FCST]))
3 RETURN
4 IF(
5     [Month Condition] = 1,
6     RealValue * [Projection Factor],
7     RealValue
8 ) -1

```

Figura 12 - Medidas em DAX para a Projeção de Valores

3.4.1.2 KPIs de Performance

Este domínio agrupa os rácios fundamentais para avaliar a eficácia do "funil" de crédito. São cruzadas pelas cinco tabelas de factos principais para obter as seguintes medidas: Médias diárias; Elegibilidade que corresponde ao rácio entre os *Score Checks* realizados e as ofertas efetivamente geradas; Conversão que indica a percentagem de ofertas enviadas que resultaram em provisionamentos aceites; Penetração indica o rácio

entre os *Score Checks* realizados e os provisionamentos aceites; Representatividade avalia o peso do valor total de crédito concedido com o valor total de carregamentos; *AVG Ticket* calcula o valor médio concedido por utilizador; *Fee%* mostra o peso das taxas de serviço cobradas face ao valor do crédito concedido.

```

1 Count Days = COUNTROWS('DATE')

1 Credit Collect = CALCULATE(SUM('COLLECTIONS'[DEBT_AMOUNT]), 'COLLECTIONS'[DEBT_TYPE] = "credit")
1 Fee Collect = CALCULATE(SUM('COLLECTIONS'[DEBT_AMOUNT]), 'COLLECTIONS'[DEBT_TYPE] = "fee")
1 Daily.31ScoreChecks =
2 VAR LastDay = TODAY() -1
3 VAR StartDate = LastDay - 30
4
5 RETURN
6 CALCULATE(
7     AVERAGEX(
8         DATESBETWEEN('DATE'[Date], StartDate, LastDay),
9         CALCULATE(SUM('SCORE_CHECKS'[SCORE_COUNT]))
10    )
11 )
1 Daily.31Offers =
2 VAR LastDay = TODAY() -1
3 VAR StartDate = LastDay - 30
4
5 RETURN
6 CALCULATE(
7     AVERAGEX(
8         DATESBETWEEN('DATE'[Date], StartDate, LastDay),
9         CALCULATE(SUM('OFFERS'[OFFER_COUNT]))
10    )
11 )
1 Daily.31Provs =
2 VAR LastDay = TODAY() -1
3 VAR StartDate = LastDay - 30
4
5 RETURN
6 CALCULATE(
7     AVERAGEX(
8         DATESBETWEEN('DATE'[Date], StartDate, LastDay),
9         CALCULATE(SUM('PROVISIONS'[PROV_COUNT]))
10    )
11 )
1 Daily.CreditCollectionDate = CALCULATE([Credit Collect], USERRELATIONSHIP('DATE'[COLLEC_DATE_TZ], COLLECTIONS[COLLEC_DATE_TZ]))
1 Daily.FeeCollectionDate = CALCULATE([Fee Collect], USERRELATIONSHIP('DATE'[COLLEC_DATE_TZ], COLLECTIONS[COLLEC_DATE_TZ]))
1 Summary.CollectionDate = CALCULATE(SUM(COLLECTIONS[COLLECT_COUNT]), USERRELATIONSHIP('DATE'[COLLEC_DATE_TZ], COLLECTIONS[COLLEC_DATE_TZ]))

1 Eligibility% = DIVIDE(SUM('OFFERS'[OFFER_COUNT]), SUM('SCORE_CHECKS'[SCORE_COUNT]))
1 Conversion% = DIVIDE(SUM('PROVISIONS'[PROV_COUNT]), SUM('OFFERS'[OFFER_COUNT]))
1 Penetration% = [Eligibility%]*[Conversion%]
1 AVG Ticket = DIVIDE(SUM('PROVISIONS'[CREDIT_AMOUNT]), SUM('PROVISIONS'[PROV_COUNT]))
1 %Fee = DIVIDE(SUM('PROVISIONS'[FEE_AMOUNT]), SUM('PROVISIONS'[CREDIT_AMOUNT]))

1 Score Checks Daily = DIVIDE(SUM('SCORE_CHECKS'[SCORE_COUNT]), [Count Days])
1 Daily Collect = DIVIDE(SUM(COLLECTIONS[COLLECT_COUNT]), [Count Days])
1 Provisions Daily = DIVIDE(SUM('PROVISIONS'[PROV_COUNT]), 'DATE'[Count Days])
1 Daily Credit = DIVIDE(SUM('PROVISIONS'[CREDIT_AMOUNT]), 'DATE'[Count Days])
1 Daily Fee = DIVIDE(SUM('PROVISIONS'[FEE_AMOUNT]), [Count Days])
1 Daily Credit Collection = DIVIDE([Credit Collect], [Count Days])

1 Daily.31Conversion = DIVIDE([Daily.31Provs], [Daily.31Offers])
1 Daily.31Eligibility = DIVIDE([Daily.31Offers], [Daily.31ScoreChecks])

```

Figura 13 - Medidas em DAX para o cálculo de KPIs

3.4.1.3 Recuperação de Bad Debt

Para a monitorização da dívida, o *Bad Debt*, foi desenvolvido um conjunto de medida focadas na análise temporal das coleções. Utilizando a dimensão de tempo e os factos de *Collections*, com auxílio da lógica DAX, permite visualizar o valor de *Bad Debt* e a velocidade de recuperação identificando quanto valor de crédito foi recuperado em cada dia após o provisionamento ser realizado, o que facilita a identificação de tendências de *Bad Debt* para diferentes meses.

```

1 Credit Collected Percentage = [Credit Collect] / SUM(PROVISIONS[CREDIT_AMOUNT])
1 Credit Collected running total in collection_time =
2 CALCULATE(
3     [Credit Collected Percentage],
4     FILTER(
5         ALLSELECTED(COLLECTIONS[COLLECTION_TIME]),
6         ISONORAFTER(COLLECTIONS[COLLECTION_TIME], MAX(COLLECTIONS[COLLECTION_TIME]), DESC)
7     )
8 )
1 Credit Collected Percentage Curve variance =
2 var pred=MAX('COLLECTIONS'[COLLECTION_TIME])-1
3 VAR prev =
4     CALCULATE(
5         [Credit Collected Percentage],
6         FILTER(
7             ALLSELECTED('COLLECTIONS'[COLLECTION_TIME]),
8             ISONORAFTER('COLLECTIONS'[COLLECTION_TIME], MAX('COLLECTIONS'[COLLECTION_TIME])-1, DESC)
9         )
10 )
11 )
12 VAR change =
13     [Credit Collected running total in collection_time] - prev
14 RETURN
15     IF ( prev = 0, BLANK (), change )
1 Bad Debt% = (SUM(PROVISIONS[CREDIT_AMOUNT])- [Credit Collect]) / SUM(PROVISIONS[CREDIT_AMOUNT])

```

Figura 14 - Medidas em DAX para o cálculo de Bad Debt e a sua recuperação ao longo do tempo

3.4.1.4 Controlling Report - Variação Semanal & Receita

Este grupo de medidas sustenta o painel de variação semanal e o painel de receita em cada projeto de *Airtime Credit*. Inclui a lógica de Variação Semanal, que automatiza a comparação de performance entre duas semanas.

Para a visão financeira foram criadas medidas que aplicam as taxas de câmbio históricas para projetar e visualizar a receita de todos os projetos numa moeda comum, em euro, permitindo uma análise comparativa da rentabilidade por projeto. Adicionalmente, quando terminado o último dia de recuperação de um mês, aplicasse uma condição que permite calcular o valor da receita através do valor de *Bad Debt* real, ao invés de uma suposição de taxa de dívida.

```

1 ControllingReport.ElegibilityWeeklyChange =
2 VAR WeekEnd =
3     CALCULATE(
4         [Elegibility%],
5         ALLSELECTED('DATE'),
6         'DATE'[PAST_WEEKS] = -1
7     )
8 VAR LastWeek =
9     CALCULATE(
10        [Elegibility%],
11        ALLSELECTED('DATE'),
12        'DATE'[PAST_WEEKS] = -2
13    )
14 VAR Difference = (WeekEnd - LastWeek) * 100
15 RETURN
16 IF(
17     ISBLANK(Difference),
18     "-",
19     FORMAT(Difference, "0.00") & " p.p."
20 )

1 ControllingReport.PenetrationWeeklyChange =
2 VAR WeekEnd =
3     CALCULATE(
4         [Penetration%],
5         ALLSELECTED('DATE'),
6         'DATE'[PAST_WEEKS] = -1
7     )
8 VAR LastWeek =
9     CALCULATE(
10        [Penetration%],
11        ALLSELECTED('DATE'),
12        'DATE'[PAST_WEEKS] = -2
13    )
14 VAR Difference = (WeekEnd - LastWeek) * 100
15 RETURN
16 IF(
17     ISBLANK(Difference),
18     "-",
19     FORMAT(Difference, "0.00") & " p.p."
20 )

1 ControllingReport.CreditWeeklyChange =
2 VAR WeekEnd =
3     CALCULATE(
4         SUM(PROVISIONS[CREDIT_AMOUNT]),
5         ALLSELECTED('DATE'),
6         'DATE'[PAST_WEEKS] = -1
7     )
8 VAR LastWeek =
9     CALCULATE(
10        SUM(PROVISIONS[CREDIT_AMOUNT]),
11        ALLSELECTED('DATE'),
12        'DATE'[PAST_WEEKS] = -2
13    )
14 RETURN
15 DIVIDE(
16     WeekEnd - LastWeek,
17     LastWeek,
18     0
19 )

1 ControllingReport.ConversionWeeklyChange =
2 VAR WeekEnd =
3     CALCULATE(
4         [Conversion%],
5         ALLSELECTED('DATE'),
6         'DATE'[PAST_WEEKS] = -1
7     )
8 VAR LastWeek =
9     CALCULATE(
10        [Conversion%],
11        ALLSELECTED('DATE'),
12        'DATE'[PAST_WEEKS] = -2
13    )
14 VAR Difference = (WeekEnd - LastWeek) * 10
15 RETURN
16 IF(
17     ISBLANK(Difference),
18     "-",
19     FORMAT(Difference, "0.00") & " p.p."
20 )

1 ControllingReport.ScoreChecksWeeklyChange =
2 VAR WeekEnd =
3     CALCULATE(
4         SUM('SCORE CHECKS'[SCORE COUNT]),
5         ALLSELECTED('DATE'),
6         'DATE'[PAST_WEEKS] = -1
7     )
8 VAR LastWeek =
9     CALCULATE(
10        SUM('SCORE CHECKS'[SCORE COUNT]),
11        ALLSELECTED('DATE'),
12        'DATE'[PAST_WEEKS] = -2
13    )
14 RETURN
15 DIVIDE(
16     WeekEnd - LastWeek,
17     LastWeek,
18     0
19 )

1 ControllingReport.ProvsWeeklyChange =
2 VAR WeekEnd =
3     CALCULATE(
4         SUM(PROVISIONS[PROV COUNT]),
5         ALLSELECTED('DATE'),
6         'DATE'[PAST_WEEKS] = -1
7     )
8 VAR LastWeek =
9     CALCULATE(
10        SUM(PROVISIONS[PROV COUNT]),
11        ALLSELECTED('DATE'),
12        'DATE'[PAST_WEEKS] = -2
13    )
14 RETURN
15 DIVIDE(
16     WeekEnd - LastWeek,
17     LastWeek,
18     0
19 )

1 ControllingReport.FeeWeeklyChange =
2 VAR WeekEnd =
3     CALCULATE(
4         SUM(PROVISIONS[FEE_AMOUNT]),
5         ALLSELECTED('DATE'),
6         'DATE'[PAST_WEEKS] = -1
7     )
8 VAR LastWeek =
9     CALCULATE(
10        SUM(PROVISIONS[FEE_AMOUNT]),
11        ALLSELECTED('DATE'),
12        'DATE'[PAST_WEEKS] = -2
13    )
14 RETURN
15 DIVIDE(
16     WeekEnd - LastWeek,
17     LastWeek,
18     0
19 )

1 ControllingReport.TopUpWeeklyChange =
2 VAR WeekEnd =
3     CALCULATE(
4         SUM(TOPUP[AMOUNT]),
5         ALLSELECTED('DATE'),
6         'DATE'[PAST_WEEKS] = -1
7     )
8 VAR LastWeek =
9     CALCULATE(
10        SUM(TOPUP[AMOUNT]),
11        ALLSELECTED('DATE'),
12        'DATE'[PAST_WEEKS] = -2
13    )
14 RETURN
15 DIVIDE(
16     WeekEnd - LastWeek,
17     LastWeek,
18     0
19 )

```

Figura 15 - Medidas em DAX para o cálculo das variações semanais

```

1 ControllingReport.Revenue =
2 VAR Fee = SUM('PROVISIONS'[FEE_AMOUNT])
3 VAR Credit = SUM('PROVISIONS'[CREDIT_AMOUNT])
4 VAR RS = SELECTEDVALUE('OPERATORS'[REVENUE SHARE%])
5 VAR RevnueType = SELECTEDVALUE('OPERATORS'[TYPE MODEL])
6 VAR MaxElapsed = SELECTEDVALUE('OPERATORS'[MAX_ELAPSED])
7 VAR YMO = SELECTEDVALUE('PROVISIONS'[OPERATOR_YEARMONTH])
8 VAR OperadorID = SELECTEDVALUE('OPERATORS'[OPERATOR_ID])
9 VAR LastDayMonth = EOMONTH(MAX('DATE'[Date]), 0)
10 VAR BadDebtFinish = LastDayMonth + MaxElapsed
11 VAR Today = TODAY()
12 VAR BD_Real = [Bad Debt%]
13 VAR BD_Assumption = SELECTEDVALUE('OPERATORS'[BAD DEBT%])
14 VAR BD_Final = IF(Today > BadDebtFinish, BD_Real, BD_Assumption)
15 VAR ExchangeLookup =
16     LOOKUPVALUE(
17         'EXCHANGE_RATES'[EXCHANGE_RATE],
18         'EXCHANGE_RATES'[OPERATOR_YEARMONTH],
19         YMO
20     )
21 VAR LastExchange =
22     CALCULATE(
23         LASTNONBLANKVALUE('EXCHANGE_RATES'[YEARMONTH], MAX('EXCHANGE_RATES'[EXCHANGE_RATE])),
24         'EXCHANGE_RATES'[OPERATOR_ID] = OperadorID,
25         ALL('DATE')
26     )
27 VAR ExchangeFinal = COALESCE(ExchangeLookup, LastExchange, 1)
28 VAR RevenueCL =
29     SWITCH( RevnueType,
30         "SHARE", ((Fee * (1 - BD_Final) - Credit * BD_Final) * RS),
31         "BEAR", (Fee * (1 - BD_Final)) * RS - Credit * BD_Final,
32         BLANK()
33     )
34 VAR RevenueEuro= DIVIDE(RevenueCL, ExchangeFinal, 0)
35 VAR CurrentMonth =
36     SELECTEDVALUE('DATE'[MONTH]) = MONTH(Today) &&
37     SELECTEDVALUE('DATE'[YEAR]) = YEAR(Today)
38
39 RETURN
40 IF(
41     CurrentMonth, RevenueEuro * [Projection Factor],RevenueEuro
42 )

```

Figura 16 - Medida em DAX para o cálculo da receita real e projetada

3.4.2 Dashboards

Os *dashboards* criados neste artefacto representam o culminar de todo o processo de engenharia, modelação e formulação de dados anteriormente descrito. É nesta etapa que os requisitos de negócio se materializam em *insights* visíveis para cumprir o objetivo final de reduzir drasticamente o tempo de análise operacional e financeira do reporte semanal, tornando-o ainda mais dinâmico.

O artefacto está organizado numa estrutura de múltiplos *dashboards*, cada um desenhado para responder a uma necessidade específica da gestão.

3.4.2.1 Controlling Report

Este é o *dashboard* central de monitorização de curto prazo e fundamental para o reporte semanal. Replica de forma automatizada a análise de variação semanal que anteriormente era executada em *Excel*. Através de uma matriz de comparação, o visualizador do artefacto consegue avaliar a performance da semana atual face à semana anterior. O diferencial deste *dashboard* reside na capacidade de apresentar a receita consolidada em euros através de um gráfico de barras, eliminando a carga de trabalho manual de conversão cambial e permitindo uma leitura imediata do impacto financeiro real por operador de forma comparativa.




Figura 17 - Dashboard sobre o Controlling Report

3.4.2.2 Forecast

Dedicado ao acompanhamento do cumprimento das metas propostas, este *dashboard* utiliza indicadores visuais em cores de "semáforo" para sinalizar o estado de cumprimento dos objetivos mensais de forma instantânea. A encarnado não se cumpre as metas (inferior

a -3% de diferença do valor projetado para o valor proposto), a verde claro indica que se atingiu as metas (no intervalo de -3% a 3%) e por fim, a verde escuro sinaliza que ultrapassou as metas propostas (diferença superior a 3%).

Adicionalmente, permite a análise do histórico do cumprimento das metas com indicadores visuais apenas no valor de crédito concedido e a sua *fee* associada, fornecendo contexto sobre a precisão das metas estabelecidas em meses anteriores.




Figura 18 - Dashboard sobre o Forecast

3.4.2.3 Performance Geral

Este dashboard foi idealizado para fornecer um diagnóstico rápido da performance do serviço. Utiliza gráficos de barras para representar o volume de eventos, como Score Checks, Ofertas e Provisionamentos, permitindo comparações entre dias, meses e anos. Inseridos juntamente, existem gráficos de linhas que são utilizados para monitorizar a evolução de indicadores como a elegibilidade e a conversão, onde a inclinação da curva revela rapidamente degradações na performance.

Um detalhe técnico fundamental neste painel é o cálculo das coleções apresentados neste *dashboard*. No capítulo 4.3.1.2 foi implementada uma medida DAX que recorre à função USERELATIONSHIP para ativar uma relação inativa no modelo relacional. Esta lógica assegura que as coleções são contabilizadas pela data de coleção e não pela data de provisionamento, como foi apresentado na tabela 2, evitando que a quantidade de coleções se acumule maioritariamente em datas antigas.

O visualizador do artefacto dispõe ainda de filtros dinâmicos para seleccionar o intervalo de tempo de análise que pretender e o operador específico que pretende avaliar.




Figura 19 - Dashboard sobre a performance geral

3.4.2.4 Recuperação do Bad Debt

Neste *dashboard*, bastante analítico, permite monitorizar a recuperação do *Bad Debt* e o comportamento do risco de cada projeto.

Para anular o efeito da sazonalidade, dado que o comportamento de coleção varia consoante o dia do mês que se encontra, o *dashboard* dispõe de um filtro por "Day of the

Month" que permite uma análise comparativa sem o factor sazonalidade. O filtro de *Elapsed Time* permite ao utilizador analisar a curva de recuperação em intervalos de dias específicos desde dia que foi concedido um crédito. No canto superior direito existe uma matriz de suporte que informa sobre os permitidos de coleção para cada projeto, servindo de auxílio para identificar o valor real da dívida.

Visualmente, o painel combina gráficos de barras para comparar montantes de *Bad Debt* com gráficos de linhas que detalham a velocidade das curvas de coleção para cada mês e dia de coleção, permitindo avaliar se a recuperação de um determinado período está a ser mais lenta que em meses anteriores.




Figura 20 - Dashboard sobre a recuperação do Bad Debt

3.4.2.5 Daily por Projeto

Neste *dashboard* o foco centra-se na avaliação e análise de desvios em relação à normalidade do projeto em questão.

No topo, os *KPIs* de "*Last 31 days average*" servem como dados comparativos que permite ao visualizador avaliar se a performance para o período selecionado está em torno

da média, se existe uma baixa de performance atípica ou se existe uma melhor performance.

A escolha de uma tabela detalhada para apresentar o histórico diário do fluxo do serviço inteiro justifica-se pela necessidade de transparência, enquanto os gráficos mostram tendências a tabela permite identificar o valor exato num determinado momento do fluxo.

Na lateral direita, o *dashboard* apresenta indicadores específicos e customizadas para cada um do projeto correspondendo às necessidades particulares que cada projeto detém.




Figura 21 - Dashboard diário de um projeto do portfólio

3.4.2.6 Dashboard Operacional por Projeto

Estes *dashboards* operacionais por projeto estão especializados para uma análise profunda em cada projeto. Ao contrário dos anteriores com visões agregadas, estes *dashboards* permitem, de tal maneira, discriminar as variáveis que influenciam a performance através de um conjunto de filtros interativos, nomeadamente o espaço de tempo “Date”, o canal por onde foi feita a comunicação do crédito “Channel” e o evento

disparador que permite realizar o *scoring* do utilizador “*Trigger*”. A interatividade destes filtros é crucial para que o visualizador consiga isolar um determinado tipo de evento ou de canal de comunicação distinto no fluxo do serviço, o que permite analisar determinada característica em cada projeto.

Estes *dashboards* estruturam-se em torno de quatro componentes fundamentais. Em primeiro lugar, destaca-se o gráfico de funil do tráfego do serviço que permite visualizar desde o início do utilizador desde o *Score Check* inicial até ao concebimento do crédito identificando com clareza em que momento do fluxo se verifica a maior retenção ou perda de potenciais utilizadores. Em segundo lugar, a distribuição de eventos de *scoring* é analisada através de gráficos de *pie charts* que segmentam os *Score Checks* por *Trigger* (RENEW, DATA_LBN) e por *Channel* (USSD, SMS), permitindo compreender qual o meio que se executa uma análise de elegibilidade para oferecer um crédito. Em terceiro lugar, um gráfico de barras apresenta os motivos de rejeição “*Denied Reasons*” que permite ao visualizador diagnosticar se as perdas de volume se devem a critérios de elegibilidade (NO OFFER AVAILABLE CREDIT LIMIT SURPASSED) ou a impedimentos técnicos (LIMIT REACHED). Finalmente, o *dashboard* inclui uma evolução temporal da penetração do serviço e dos eventos negados para ofertas e ofertas realizadas que garantem que o visualizador possui todas as características necessárias para otimizar o serviço para cada operador específico.



Figura 22 - Dashboard operacional por projeto

3.5 Estratégia de Avaliação

A avaliação é a fase que determina se o artefacto apoia efetivamente a resolução do problema (Hevner et al., 2004). O processo de avaliação deste TFM será feito através de critérios de eficiência e eficácia. Na eficiência será medido o tempo necessário para obter a visão semanal completa, validando se o objetivo de redução para cerca de dez minutos foi atingido. Será também verificado os resultados gerados pelo *Power BI* e o ficheiro anteriormente usado de forma manual para assegurar a integridade dos dados.

Este processo iterativo permitirá realizar ajustes finais no artefacto antes da sua entrega, garantindo que a solução proposta é robusta e fidedigna.

4 RESULTADOS

Nesta parte irá ser feita a demonstração e a avaliação do artefacto desenvolvido nos capítulos anteriores, conforme planeado pela metodologia DSR. O objetivo deste capítulo é validar se a solução de *Business Intelligence* implementada no artefacto cumpre os requisitos da realização do reporte semanal e eficácia, resolvendo o problema da extração de dados identificado no início deste trabalho. Através da exploração de cenários reais e da análise comparativa de desempenho, irá ser demonstrado como a transição do modelo manual para o automatizado acresce valor de decisão e de performance no reporte semanal de *Airtime Credit*.

4.1 Demonstração de Cenários Realistas

A demonstração do artefacto consiste na aplicação prática do *Power BI* em momentos reais para a avaliação de projetos e tomada de decisão. Um dos cenários mais importante observados durante a utilização desta ferramenta é a monitorização da variação semanal da performance dos projetos pertencentes ao portfólio de *Airtime Credit* através do *dashboard* de *Controlling Report*. Neste cenário, o visualizador deixa de executar *queries* semanalmente e de forma manual para colocar em um ficheiro *Excel* e passa a identificar, após atualizar os dados do artefacto, desvios das métricas apresentadas na figura 17.

Por exemplo, ao observar a performance semanal de operadores com o ID 1 ou 508, o sistema sinaliza variações percentuais e de pontos percentuais (p.p.) que, no modelo anterior, apenas seriam visualizados quando todas as *queries* para cada métrica fossem processadas e exportadas para o ficheiro *Excel* de forma manual. A capacidade de observar a receita em euros, com a execução automática das taxas de câmbio, permite dispor o histórico de todas as receitas com a taxa de câmbio correspondente a cada projeto e mês, algo que no formato anterior do artefacto seria impossível analisar de forma direta.

Outro cenário de elevada relevância estratégica é o cumprimento das metas através do *dashboard* de FCST. Utilizando o fator de projeção implementado criado em DAX, o artefacto demonstra a sua capacidade preditiva ao indicar, a meio do mês, se a tendência atual de provisionamentos, por exemplo, irá de encontro os objetivos delineados pela equipa. Numa demonstração prática, observou-se que a ferramenta consegue identificar que projetos irão atingir os valores FCST, sinalizados a verde, e, simultaneamente, mostrar o histórico de meses anteriores para validar se as metas foram cumpridas, algo

que também na execução manual não era possível de forma direta. Esta visibilidade permite que a equipa de *Airtime Credit* tome medidas corretivas, antes do final do mês para conseguir atingir as metas propostas.

Por fim, a demonstração da análise de recuperação da dívida, em *Recovery Bad Debt*, revela a utilidade do artefacto na monitorização da saúde financeira do portfólio. Ao filtrar pelo dia do mês e pelo tempo de recuperação, *Elapsed Time*, o visualizador consegue observar as curvas de recuperação de crédito e comparar em diferentes meses. Num cenário real, o visualizador consegue detetar de forma direta se existe abrandamento na coleção, a curva fica mais plana, ou se está a ocorrer um aceleração da recuperação, a curva apresenta-se linearmente crescente. Esta capacidade de escolher dia do provisionamento e o dia de recuperação permite passar da visão global para um determinado dia recuperação, o que fornece a ferramenta de poder analisar o *Bad Debt* quando, por exemplo, se faz uma alteração no modelo de decisão de oferta para que seja possível a avaliar a consequência do valor de *Bad Debt* após essa implementação, ignorando os dias e meses anteriores quando o modelo de decisão era diferente.

4.2 Avaliação de Eficiência

A avaliação de eficiência foca-se na duração do tempo da extração dos dados, que constitui o principal motivador deste trabalho. Antes da implementação do artefacto de BI, o processo de controlo era caracterizado por um fluxo de trabalho linear e intensivo de forma manual, extraíndo os dados em *data warehouse* de múltiplas tabelas com diferentes restrições, atualizando e criando ficheiros manualmente que consumia, em média, quatro horas de trabalho para uma única análise semanal. Esta ação traduzia-se num processo demorado e incómodo, uma vez que o analista dedicava a maior parte do seu tempo a carregar e a preparar os dados em vez da interpretação da performance dos projetos.

Com a entrada em funcionamento do artefacto desenvolvido em *Power BI*, o tempo total do processo, desde a extração automática das tabelas agregadas até à visualização final dos *dashboards*, foi reduzido para sete minutos, em média. Esta redução significativa de aproximadamente 97%, valida o cumprimento do objetivo principal deste TFM.

A eficiência não se manifesta apenas na rapidez da obtenção dos dados mas também na visibilidade dos gráficos e na frequência de utilização como é mostrado da figura 23 até à figura 25.

06/04 - 12/04					13/04 - 19/04				
	1	508	17110	43111		1	508	17110	43111
TopUp Amount	61 140 991	399 151 078	325 008 744	1 262 304	TopUp Amount	62 235 571	429 321 842	339 313 012	1 316 023
Offer	6 955 118	2 812 766	589 052	115 324	Offer	6 204 967	3 139 186	605 339	118 828
Denied	5 525 353	1 891 615	712 142	857 286	Denied	5 295 852	2 191 213	698 833	909 877
Score Check	12 480 471	4 704 381	1 301 194	972 610	Score Check	11 500 819	5 330 399	1 304 172	1 028 705
Eligibility (%)	55,73%	59,79%	45,27%	11,86%	Eligibility (%)	53,95%	58,89%	46,42%	11,55%
Provisions	270 476	145 454	23 713	1 174	Provisions	253 438	154 741	23 668	1 195
Credit - LC	4 310 286	6 614 870	25 786 525	5 870	Credit - LC	4 000 285	6 898 530	26 020 500	5 975
Fee - LC	2 155 314	1 375 760	5 157 305	2 348	Fee - LC	2 000 313	1 454 040	5 204 100	2 390
Conversion (%)	3,89%	5,17%	4,03%	1,02%	Conversion (%)	4,08%	4,93%	3,91%	1,01%
Penetration (%)	2,17%	3,09%	1,82%	0,12%	Penetration (%)	2,20%	2,90%	1,81%	0,12%

Service Revenue Forecast 04					Change from last week				
	1	508	17110	43111		1	508	17110	43111
Credit - LC	17 906 714	28 740 442	106 347 789	25 247	TopUp Amount	1,79%	7,56%	4,40%	4,26%
Fee - LC	8 954 069	6 004 026	21 269 558	10 099	Offer	-10,79%	11,60%	2,76%	3,04%
Bad Debt%	15,00%	4,75%	4,00%	16,00%	Denied	-4,15%	15,84%	-1,87%	6,13%
Unpaid Credit - LC	2 686 007	1 365 171	723 165	4 040	Score Check	-7,85%	13,31%	0,23%	5,77%
Fee Collected - LC	7 610 958	5 718 835	20 418 776	8 483	Eligibility	-1,78 p.p.	-0,9 p.p.	1,15 p.p.	-0,31 p.p.
TWT Revenue	146 534 €	86 547 €	4 990 €	431 €	Provisions	-6,30%	6,38%	-0,19%	1,79%
					Credit - LC	-7,19%	4,29%	0,91%	1,79%
					Fee - LC	-7,19%	5,69%	0,91%	1,79%
					Conversion	0,2 p.p.	-0,24 p.p.	-0,12 p.p.	-0,01 p.p.
					Penetration	0,04 p.p.	-0,19 p.p.	-0,01 p.p.	0 p.p.

Figura 23 - Página do ficheiro Excel antigo sobre o Controlling Report

	2024	2025	2026														
Eligibilidade			Taxa de Elegibilidade (%)														
Operadora	Total	Total	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Total	Atual	FCST 04
VIVO	52,38%	63,86%	58,51%	57,49%	56,62%	55,80%									57,19%	55,80%	57,10%
AT&T	70,39%	64,90%	60,08%	55,39%	57,16%	59,69%									57,87%	59,69%	57,16%
Liberty	87,44%	45,67%	46,50%	45,29%	44,54%	46,37%									45,61%	46,37%	45,44%
Ooredoo P	7,25%	7,95%	11,51%	11,84%	11,71%	11,71%									11,69%	11,71%	11,71%

Conversão			Taxa de Conversão (%)														
Operadora	Total	Total	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Total	Atual	FCST 04
VIVO	6,00%	4,69%	3,62%	3,59%	3,80%	3,89%									3,72%	3,89%	3,80%
AT&T	0,74%	2,87%	3,58%	4,29%	4,83%	4,95%									4,33%	4,95%	4,83%
Liberty	7,05%	5,73%	4,15%	4,21%	3,92%	3,77%									4,04%	3,77%	4,09%
Ooredoo P	0,28%	0,44%	1,07%	1,00%	0,94%	1,02%									1,00%	1,02%	0,94%

Penetração			Taxa de Penetração														
Operadora	Total	Total	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Total	Atual	FCST 04
VIVO	3,14%	2,99%	2,12%	2,06%	2,15%	2,17%									2,13%	2,17%	2,17%
AT&T	0,52%	1,86%	2,15%	2,38%	2,76%	2,96%									2,50%	2,96%	2,76%
Liberty	6,17%	2,62%	1,93%	1,91%	1,75%	1,75%									1,84%	1,75%	1,86%
Ooredoo P	0,02%	0,03%	0,12%	0,12%	0,11%	0,12%									0,12%	0,12%	0,11%

Bad Debt			BD 2026 (%)														
Operadora			Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez			
VIVO			19,62%	25,67%	48,37%	82,87%											
AT&T			5,97%	6,06%	10,87%	48,74%											
Liberty			5,23%	6,90%	11,73%	40,77%											
Ooredoo P			21,84%	23,24%	33,49%	60,47%											

	Operador	VIVO	AT&T	Liberty	Ooredoo P
Vigência(dia)		105	90	365	180

Figura 24 - Página do ficheiro Excel antigo sobre os indicadores mensais

Operadora	Total 2024	Total 2025	Jan	Fev	Mar	Abr	Total 2026	Atual	FCST 04	
1	21 687 581	8 848 435	977 090	816 157	1 048 244	710 448	3 551 939	1 121 798	1 339 918	84%
508	1 004 890	6 490 934	556 750	621 440	673 158	402 246	2 253 594	635 125	651 443	87%
17110	2 294 218	1 693 562	119 753	106 197	103 741	61 332	391 023	96 840	106 922	81%
43 111	51 026	58 129	5 249	4 711	4 758	3 198	17 916	5 049	4 605	110%
Total	152 823 172	148 867 842	12 060 921	10 863 483	12 497 353	7 432 220	42 853 977			
Operadora	Total 2024	Total 2025	Jan	Fev	Mar	Abr	Total 2026	Atual	FCST 04	Atual em €
1	243 860 751	136 472 269	15 915 332	13 464 899	17 186 283	11 340 919	57 907 433	17 908 714	21 968 372	2 959 914,61 €
508	36 598 735	284 572 530	25 234 855	27 338 090	29 934 940	18 202 280	100 710 165	28 748 442	28 969 297	1 397 473,60 €
17110	2 396 611 377	1 794 679 350	132 783 975	116 427 875	112 716 300	67 353 600	429 281 750	106 347 789	117 317 108	193 122,95 €
43 111	255 130	290 645	26 245	23 555	23 790	15 990	89 580	25 247	23 023	6 992,41 €
Total	158 150 627 635	192 869 947 502	15 263 730 368	13 707 137 653	16 108 787 762	10 071 197 100	55 150 862 883			
Operadora	Total 2024	Total 2025	Jan	Fev	Mar	Abr	Total 2026	Atual	FCST 04	Atual em €
1	108 480 112	68 214 122	7 958 119	6 732 815	8 593 672	5 670 910	28 955 516	8 934 089	10 984 864	1 480 074,98 €
508	9 220 010	60 547 850	5 217 495	5 797 280	6 326 890	3 802 550	21 144 215	6 004 828	6 122 797	291 939
17110	359 243 656	279 765 878	26 556 795	23 285 575	22 543 260	13 470 720	85 856 350	21 288 358	23 463 422	38 624,59 €
43 111	102 052	116 258	10 498	9 422	9 516	6 396	35 832	10 099	9 209	2 797
Total	14 958 759 446	25 393 790 774	2 120 998 171	1 904 650 853	2 247 623 473	1 430 164 521	7 703 436 218			

Figura 25 - Página do ficheiro Excel antigo sobre os resultados de provisionamentos, crédito dado e fee associada.

Agora, neste artefacto em BI, é possível analisar de forma diária através dos *Dailies* de cada projeto que antes não era possível analisar no ficheiro Excel, apenas a partir de *queries* para extrair os valores da *Data Warehouse*. Esta redução de tempo permite que o analista utilize a maioria do seu tempo de trabalho na análise das diferenças semanais e diárias, tendências de métricas e otimização de projetos, elevando o nível do conteúdo do reporte enviado.

4.3 Avaliação de Eficácia e Precisão

A eficácia do artefacto foi validada através da comparação dos valores do *Controlling Report*, de modo a avaliar a precisão e integridade dos dados como mostra a figura em baixo.

Dados do artefacto de BI criado para entre os dias 13 e 19 de abril de 2026

Performance from 2 Weeks Ago

	1	508	17110	43111
TopUp Amount	61.140.991	397.595.465	362.609.465	1.262.304
Score Checks	12.138.575	4.424.726	1.317.608	914.379
Elegibility%	57,30%	63,57%	45,39%	12,61%
Offers	6.955.118	2.812.766	598.052	115.324
Conversion%	3,89%	5,15%	3,97%	1,02%
Provisions	270.476	144.956	23.713	1.174
Credit	4.310.286	6.592.625	25.786.525	5.870
Fee	2.155.314	1.371.065	5.157.305	2.348
Penetration%	2,23%	3,28%	1,80%	0,13%

Last Week Performance

	1	508	17110	43111
TopUp Amount	62.235.571	430.689.483	378.522.492	1.316.023
Score Checks	11.189.588	4.972.720	1.320.186	968.037
Elegibility%	55,45%	63,13%	45,85%	12,28%
Offers	6.204.967	3.139.186	605.339	118.828
Conversion%	4,08%	4,93%	3,91%	1,01%
Provisions	253.438	154.741	23.668	1.195
Credit	4.000.285	6.898.530	26.020.500	5.975
Fee	2.000.313	1.454.040	5.204.100	2.390
Penetration%	2,26%	3,11%	1,79%	0,12%

%Change from Last Week

	1	508	17110	43111
TopUp Amount	1,79%	8,32%	4,39%	4,26%
Score Checks	-7,82%	12,38%	0,20%	5,87%
Elegibility	-1,84 p.p.	-0,44 p.p.	0,46 p.p.	-0,34 p.p.
Offers	-10,79%	11,60%	1,22%	3,04%
Conversion	0,20 p.p.	-0,22 p.p.	-0,06 p.p.	-0,01 p.p.
Provisions	-6,30%	6,75%	-0,19%	1,79%
Credit	-7,19%	4,64%	0,91%	1,79%
Fee	-7,19%	6,05%	0,91%	1,79%
Penetration	0,04 p.p.	-0,16 p.p.	-0,01 p.p.	0,00 p.p.

Dados do ficheiro Excel para entre os dias 13 e 19 de abril de 2026

06/04 - 12/04					13/04 - 19/04					Change from last week				
	1	508	17110	43111		1	508	17110	43111		1	508	17110	43111
TopUp Amount	61.140.991	399.151.078	325.008.744	1.262.304	TopUp Amount	62.235.571	429.321.842	339.313.012	1.316.023	TopUp Amount	1,79%	7,56%	4,40%	4,26%
Offer	6.955.118	2.812.766	589.052	115.324	Offer	6.204.967	3.139.186	605.339	118.828	Offer	-10,79%	11,60%	2,76%	3,04%
Denied	5.525.353	1.891.615	712.142	857.286	Denied	5.295.852	2.191.213	698.833	909.877	Denied	-4,15%	15,84%	-1,87%	6,13%
Score Check	12.480.471	4.704.381	1.301.194	972.610	Score Check	11.500.819	5.330.399	1.304.172	1.028.705	Score Check	-7,85%	13,31%	0,23%	5,77%
Elegibility (%)	55,73%	59,79%	45,27%	11,86%	Elegibility (%)	53,95%	58,89%	46,42%	11,55%	Elegibility	-1,78 p.p.	-0,9 p.p.	1,15 p.p.	-0,31 p.p.
Provisions	270.476	145.454	23.713	1.174	Provisions	253.438	154.741	23.668	1.195	Provisions	-6,30%	6,38%	-0,19%	1,79%
Credit - LC	4.310.286	6.614.870	25.786.525	5.870	Credit - LC	4.000.285	6.898.530	26.020.500	5.975	Credit - LC	-7,19%	4,29%	0,91%	1,79%
Fee - LC	2.155.314	1.375.760	5.157.305	2.348	Fee - LC	2.000.313	1.454.040	5.204.100	2.390	Fee - LC	-7,19%	5,69%	0,91%	1,79%
Conversion (%)	3,89%	5,17%	4,03%	1,02%	Conversion (%)	4,08%	4,93%	3,91%	1,01%	Conversion	0,2 p.p.	-0,24 p.p.	-0,12 p.p.	-0,01 p.p.
Penetration (%)	2,17%	3,09%	1,82%	0,12%	Penetration (%)	2,20%	2,90%	1,81%	0,12%	Penetration	0,04 p.p.	-0,19 p.p.	-0,01 p.p.	0 p.p.

Figura 26 - Comparação dos valores exportados em cada artefacto

Durante este processo de comparação, identificaram-se ligeiras discrepâncias em operadores específicos, nomeadamente no 508 e 17110, onde as variações ocorrem nas ofertas realizadas e no valor de *Top-up*. É necessário clarificar que estas divergências decorrem da diferença de origem nas fontes de dados. Enquanto os dados do *Excel* são provenientes de tabelas transacionais, o *Power BI* utiliza tabelas agregadas para maximizar o tempo de atualização dos dados.

Estas variações provavelmente são justificadas por fatores técnicos da infraestrutura de dados de BI, como os horários de processamento das tabelas agregadas configurados pela equipa especializada em *Business Intelligence*, que podem não coincidir exatamente com a extração transacional, ou falhas pontuais nos *jobs* de agregação.

No entanto, a margem de erro identificada é inferior a 2% para as métricas com discrepância, um valor estatisticamente irrelevante para a análise de tendências que o artefacto se propõe a realizar e as métricas fundamentais para o valor do negócio não apresentam divergências entre os ficheiros, o que torna o principal pilar do *Airtime Credit* (valor de crédito concedido) fidedigno não comprometendo a veracidade da análise.

É necessário dar especial atenção à validação da função USERRELATIONSHIP nas coleções, onde se comprovou que o sistema contabiliza corretamente os valores recuperados por data de pagamento, eliminando distorções de acumulação histórica.

5 CONCLUSÃO

O presente Trabalho Final de Mestrado teve como propósito a conceção, o desenvolvimento e a avaliação de um artefacto de *Business Intelligence* destinado à monitorização da performance e análise em projetos de *Airtime Credit*. Através da aplicação da DSR, foi possível desenvolver uma solução dinâmica e fidedigna que respondeu diretamente à lacuna identificada na realização da tarefa de realizar um reporte semanal, o elevado tempo de execução na extração e tratamento de dados.

As contribuições deste trabalho são tanto técnicas como estratégicas. Do ponto de vista técnico, demonstrou-se a eficácia de um modelo dimensional baseado num esquema estrela com tabelas agregadas, que permite um processamento rápido de métricas complexas sem comprometer o desempenho da do artefacto. As implementações das medidas criadas em DAX para projeções de *Forecast*, análise de velocidade de recuperação e *KPIs* permitiu dotar a organização de uma capacidade analítica que transcende a mera visualização de dados históricos. A nível estratégico, o projeto atingiu nitidamente a meta ambiciosa de reduzir o tempo de extração de dados e estruturação dos elementos visuais para análise de 4 horas para dez minutos, proporcionando elementos visuais diretos e dinâmicos à informação e permitindo um controlo proativo que é fundamental num setor como as telecomunicações e microcrédito.

Contudo, o trabalho não está isento de limitações. A dependência da qualidade e da atualização das tabelas agregadas na *Data Warehouse* central significa que qualquer atraso na infraestrutura de dados de origem impacta a frescura da informação no *dashboard*, como foi mostrado no capítulo 4.3.

Da maneira como o artefacto está modelado, facilmente e de maneira prática é possível acrescentar futuros operadores de comunicação aos *dashboards*, o que mostra a versatilidade do artefacto criado tanto para novos operadores como indicadores de análise comuns.

Para futuro trabalhos deste âmbito, sugiro a evolução do artefacto para uma vertente preditiva utilizando ML e a utilização AI para a criação das análises dos reportes semanais. A integração de modelos ML iria permitir monitorizar o *Bad Debt* e a probabilidade de incumprimento de grupos de utilizadores, *ratings* por exemplo, que antes mesmo da concessão do crédito. A utilização de AI sobre as análises teria como

propósito de interpretar as variações de performance e explicar as causas das variações de acordo com as métricas do fluxo. Esta evolução transformaria o reporte semanal em uma ferramenta de consultoria inteligente, capaz de explicar acontecimentos semanais de forma autónoma.

Em resumo, este TFM cumpriu os seus objetivos iniciais, entregando uma solução tecnológica validada que representa uma melhoria qualitativa na eficiência do reporte semanal e na duração do cumprimento desta tarefa no âmbito de *Airtime Credit*.

BIBLIOGRAFIA

- Andrienko, G., Andrienko, N., Drucker, S. M., Fekete, J.-D., Fisher, D., Idreos, S., Kraska, T., Li, G., Ma, K.-L., Mackinlay, J. D., Drucker, S., Oulasvirta, A., Schreck, T., Schmann, H., Stonebraker, M., Auber, D., Bikakis, N., Chrysanthos, P. K., Papastefanatos, G., & Sharaf, M. A. (2020). Big Data Visualization and Analytics: Future Research Challenges and Emerging Applications. *Big Data Visual Exploration and Analytics*. <https://inria.hal.science/hal-02568845>
- Aparicio, M., & Costa, C. J. (2015). Data visualization. *Communication Design Quarterly Review*, 3(1), 7-11. <https://dl.acm.org/doi/10.1145/2721882.2721883>
- Aparicio, J.T., Aparicio, M., Costa, C.J. (2023). Design Science in Information Systems and Computing. In: Anwar, S., Ullah, A., Rocha, Á., Sousa, M.J. (eds) *Proceedings of International Conference on Information Technology and Applications. Lecture Notes in Networks and Systems*, vol 614. Springer, Singapore. https://link.springer.com/chapter/10.1007/978-981-19-9331-2_35
- Babeta, S. N., & Meshesha, M. (2024). Telecom airtime credit risk prediction using machine learning. *INTERNATIONAL JOURNAL OF RESEARCH*, 6(2), 14-20.
- Bikakis, N. (2022). Big Data Visualization Tools. *Encyclopedia of Big Data Technologies*, 1–8. https://link.springer.com/rwe/10.1007/978-3-319-63962-8_109-2
- Cairo, A. (2016). *The truthful art: Data, charts, and maps for communication*. New Riders.
- Chaudhuri, S., Dayal, U., & Narasayya, V. (2011). An overview of business intelligence technology. In *Communications of the ACM* (Vol. 54, Issue 8, pp. 88–98). <https://doi.org/10.1145/1978542.1978562>
- Chen, H., Chiang, R. H. L., & Storey, V. C. (2012). Business Intelligence and Analytics: From Big Data to Big Impact. *MIS Quarterly*, 36(4), 1165–1188. <https://doi.org/10.2307/41703503>

- Codd, E. F. (1970). A relational model of data for large shared data banks. *Communications of the ACM*, 13(6), 377-387. <https://dl.acm.org/doi/10.1145/362384.362685>
- Codd, E. F. (1971). Further normalization of the data base relational model. *Data Base Systems*, 1-33. <https://forum.thethirdmanifesto.com/wp-content/uploads/asgarosforum/987737/00-efc-further-normalization.pdf>
- Costa, C. J., & Aparicio, M. (2019). Supporting the decision on dashboard design charts. *Proceedings of 254th The IIER International Conference*, Saint Petersburg, Russia, 10–15
- Cottur, K., & Gadad, V. (2020). Design and Development of Data Pipelines. *International Research Journal of Engineering and Technology*.
- Crapo, A. W., Waisel, L. B., Wallace, W. A., & Willemain, T. R. (2000). Visualization and the process of modeling. 218–226.
- Davenport, T. (2006). Competing on Analytics. *Harvard Business Review*, 84, 98–107, 134.
- Few, S. (2009). Now You See it: Simple Visualization Techniques for Quantitative Analysis. Analytics Press. <https://pt.scribd.com/document/843228286/Now-You-See-It-Simple-Visualization-Techniques-for-Quantitative>
- Few, S. (2012). *Show Me the Numbers: Designing Tables and Graphs to Enlighten* (2nd ed.). Analytics Press. <https://pt.scribd.com/document/453762006/Show-Me-the-Numbers-by-Stephen-Few-2012-pdf>
- Hevner, A. R., March, S. T., Park, J., & Ram, S. (2004). Design science in information systems research. *MIS Quarterly*, 28(1), 75-105. <https://doi.org/10.2307/25148625>
- Inmon, W. H. (2005). *Building the Data Warehouse* (4th ed.). John Wiley & Sons.
- Kimball, R., & Ross, M. (2002). *The Data Warehouse Toolkit: The Complete Guide to Dimensional Modeling*. John Wiley & Sons.

- Linstedt, D., & Olschimke, M. (2015). *Building a Scalable Data Warehouse with Data Vault 2.0*. Morgan Kaufmann.
- Lu, J. (2022). Data Science in the Business Environment: Architecture, Process and Tools. *Communications in Computer and Information Science*, 1528 CCIS, 279–293. https://www.researchgate.net/publication/358434144_Data_Science_in_the_Business_Environment_Architecture_Process_and_Tools
- Luhn, H. P. (1958). A Business Intelligence System. *IBM Journal of Research and Development*, 2(4), 314–319. <https://ieeexplore.ieee.org/document/5392644>
- Madise, S. (2015). *The regulation of mobile money in Malawi: A case study of a developing economy*. [Tese de Doutoramento, University of Warwick].
- March, S. T., & Smith, G. F. (1995). Design and natural science research on information technology. *Decision Support Systems*, 15(4), 251–266. <https://pt.scribd.com/document/234690451/Design-and-Natural-Science-Research-on-Information-Technology>
- Munzner, T. (2014). *Visualization analysis and design*. CRC Press.
- Peppers, K., Tuunanen, T., Rothenberger, M. A., & Chatterjee, S. (2008). A design science research methodology for information systems research. *Journal of Management Information Systems*, 24(3), 45–77. <https://www.tandfonline.com/doi/abs/10.2753/MIS0742-1222240302>
- Reeve, A. (2013). Extract, Transform, and Load. In *Managing Data in Motion* (pp. 29–35). Morgan Kaufmann. <https://www.sciencedirect.com/science/chapter/monograph/abs/pii/B9780123971678000066?via%3Dihub>
- Shao, C., Yang, Y., Juneja, S., & G. Seetharam, T. (2022). IoT data visualization for business intelligence in corporate finance. *Information Processing & Management*, 59(1), 102736. <https://www.sciencedirect.com/science/article/abs/pii/S0306457321002181?via%3Dihub>

- Shema, A. (2021). *Leveraging mobile airtime usage for credit scoring in data-poor environments*. [Tese de Doutorado, Clemson University]
- Simon, H. A. (1996). *The Sciences of the Artificial* (3rd ed.). MIT Press.
- Tufte, E. R. (2001). *The Visual Display of Quantitative Information* (2nd ed.). Graphics Press.
- Turban, E., & Aronson, J. E. (1998). *Decision Support Systems and Intelligent Systems*. Prentice Hall.
- Turban, E., Sharda, R., & Delen, D. (2014). *Business Intelligence and Analytics: Systems for Decision Support*. Pearson Education.
- Vitt, E., Luckevich, M., & Misner, S. (2002). *Business Intelligence: Making Better Decisions Faster*. Microsoft Press.
<https://archive.org/details/businessintellig0000vitt/page/12/mode/2up>