



Graduação Pós-Graduação
 Artigo completo Relato de prática Resumo expandido

**CARGA COGNITIVA, FINANÇAS COMPORTAMENTAIS E INTELIGÊNCIA
ARTIFICIAL NO APOIO À SELEÇÃO DE AÇÕES DE DIVIDENDOS: Proposição
Arquitetural da Carteira Inteligente IA**

Renato de Oliveira Rosa
Fucape
gestor.renatorosa@gmail.com

RESUMO

O crescimento do número de investidores pessoa física no mercado de capitais brasileiro ampliou o acesso à renda variável, mas não eliminou a assimetria informacional nem a limitação técnica para interpretar dados contábeis e financeiros. Nesse contexto, dashboards de plataformas tradicionais concentram múltiplos indicadores, séries históricas, filtros e telas, impondo ao usuário elevado esforço de processamento mental. Conseqüentemente, a decisão de investimento pode ser afetada por sobrecarga cognitiva, fadiga decisória e vieses descritos pelas Finanças Comportamentais. Diante disso, este artigo propõe a arquitetura conceitual da Carteira Inteligente IA, um modelo de linguagem configurado para apoiar a seleção de ações voltadas a dividendos por meio de interação em linguagem natural e integração com APIs externas. Desse modo, o artefato foi delineado com base na Design Science Research, articulando Teoria da Carga Cognitiva, Finanças Comportamentais e sistemas conversacionais. Ademais, o modelo foi idealizado para consumir dados do Yahoo Finance via RapidAPI, processar indicadores como payout e dividend yield e devolver relatórios estruturados, comparáveis e rastreáveis. Portanto, argumenta-se que a solução atua como mediação cognitiva ao reduzir ruído visual, condensar dados dispersos e apoiar a interpretação de métricas financeiras sem transferir a decisão final ao sistema.

Palavras-chave: Carga Cognitiva; Finanças Comportamentais; Inteligência Artificial; Dividendos; Investidor Pessoa Física.

EIXO 4 - Artigo Completo - Inovação, Tecnologia e Empreendedorismo

1 INTRODUÇÃO

O mercado de capitais brasileiro passou por uma expansão expressiva na participação de investidores pessoa física nos últimos anos. O número de CPFs ativos na B3 saltou de patamares inferiores a um milhão em 2018 para dezenas de milhões de participantes no ciclo recente, impulsionado pela difusão de plataformas digitais e pela oferta ampliada de produtos financeiros (Infomoney, 2020; Poder360, 2023; B3, 2024a; B3, 2025). Esse movimento, embora tenha democratizado o acesso operacional ao investimento, não assegurou a internalização dos conhecimentos contábeis, financeiros e estatísticos necessários à análise autônoma de ativos.

Nesse contexto, a assimetria informacional permanece como uma restrição severa para o investidor independente. A leitura de demonstrativos, a comparação setorial e a interpretação de indicadores fundamentais como payout, dividend yield, retorno sobre patrimônio líquido (ROE), fluxo de caixa operacional e endividamento demandam um repertório técnico frequentemente ausente entre os novos participantes (Amorim et al., 2018; Barbosa, 2022; Wisniewski, 2011). Além disso, a difusão desigual da educação financeira no país agrava a distância entre o mero acesso à plataforma corretora e a real capacidade de decisão do indivíduo.

Sob a ótica da interação humano computador, o problema não se limita à ausência de conhecimento formal. Conseqüentemente, a própria forma como a informação é apresentada nas plataformas de investimento impõe múltiplas demandas simultâneas de atenção, memória de trabalho, comparação visual e alternância entre telas. Ademais, dashboards de mercado usualmente exibem cotações, indicadores, notícias, calendários de proventos, gráficos, rankings e filtros em paralelo, o que amplia a exigência cognitiva para a transformação de dados dispersos em inferências operacionais.

Nesse cenário, a Teoria da Carga Cognitiva oferece uma lente útil para compreender o esforço mental imposto ao investidor. Conseqüentemente, quando a memória de trabalho é ocupada por volume elevado de estímulos, interfaces fragmentadas e tarefas de integração de dados, a capacidade de julgamento tende a ser reduzida. Paralelamente, as Finanças Comportamentais indicam que decisões sob pressão informacional e sob processamento incompleto podem ser capturadas por heurísticas, vieses de disponibilidade, ancoragem, excesso de confiança e fadiga decisória.

Diante disso, modelos de linguagem de grande escala surgem como alternativa de mediação entre volume de dados e capacidade humana de interpretação. Conseqüentemente, ao receber perguntas em linguagem natural e devolvê-las em formato estruturado, esses sistemas



podem funcionar como camada de tradução entre bases financeiras e necessidades cognitivas do usuário. Ademais, sua utilidade não decorre de substituir o investidor, mas de reorganizar a informação de modo compatível com limites humanos de atenção e processamento.

Nesse sentido, o problema de pesquisa deste artigo consiste em examinar de que modo uma arquitetura de inteligência artificial conversacional voltada a dividendos pode reduzir a carga cognitiva associada ao uso de plataformas tradicionais de análise de investimentos. Conseqüentemente, o objetivo do estudo é propor a arquitetura da Carteira Inteligente IA, concebida como artefato de apoio à seleção de ações pagadoras de dividendos, estruturado por linguagem natural, prompts especializados e integração com APIs financeiras auditáveis. Portanto, o argumento central sustenta que a IA pode atuar como prótese cognitiva ao filtrar ruído visual, consolidar indicadores e reduzir o esforço de navegação e correlação manual entre múltiplas telas.

2 REVISÃO DA LITERATURA

2.1 Finanças Comportamentais e Sobrecarga Cognitiva

O processo decisório no mercado de capitais envolve mais do que o acesso formal à informação. Conseqüentemente, a decisão do investidor pessoa física depende da interação entre disponibilidade de dados, capacidade individual de interpretação e condições práticas de uso dessas informações. Ademais, Amorim, Lucena, Girão e Queiroz (2018) demonstram que a inserção de investidores no mercado de capitais está associada ao nível de educação financeira, indicando que a tomada de decisão não ocorre apenas a partir de fundamentos objetivos, mas também a partir das competências cognitivas mobilizadas para compreender risco, retorno e alocação. Paralelamente, Wisniewski (2011) sustenta que a popularização do mercado de capitais não foi acompanhada, em igual medida, pela formação técnica necessária para a gestão informada das finanças pessoais, o que amplia a vulnerabilidade decisória do investidor não profissional.

Nesse plano, a dificuldade de interpretar informações contábeis e financeiras atua como um forte catalisador da carga cognitiva no ambiente de investimento. Barbosa (2022) observa que novos investidores pessoa física apresentam limitações recorrentes para compreender conceitos basilares e operar com autonomia no mercado acionário brasileiro. Como as iniciativas de educação financeira ainda possuem alcance geográfico e social desigual (ANBIMA, 2022), as lacunas na capacidade de leitura técnica persistem. Logo, quando o investidor precisa processar múltiplos indicadores, relatórios e telas sem um repertório



previamente consolidado, o esforço mental exigido para localizar e interpretar dados aumenta exponencialmente.

Sob essa ótica, as plataformas tradicionais de investimento acabam intensificando essa exigência cognitiva. Ao apresentarem, de forma simultânea, cotações, gráficos, notícias e calendários de proventos, obrigam o investidor a articular diferentes fontes dispersas para avaliar um único ativo. Essa dinâmica sobrecarrega a memória de trabalho do indivíduo, exigindo alta retenção temporária de informações e esforço contínuo de comparação entre períodos e empresas.

Ademais, Medeiros, Vasconcelos e De Luca (2023) indicam que a qualidade das informações contábeis afeta a percepção de risco no mercado acionário, sugerindo que a interpretação inadequada ou incompleta de dados financeiros pode comprometer a avaliação do investidor. Paralelamente, Ventura, Figueiredo, Ventura Júnior, Teixeira e Macagnan (2023) mostram que a qualidade do reporte financeiro depende de fatores institucionais e de governança, o que reforça a necessidade de leitura criteriosa e contextualizada dos dados disponíveis ao mercado.

Nesse ambiente, a sobrecarga informacional pode favorecer decisões baseadas em simplificações cognitivas. Conseqüentemente, quando o investidor não consegue integrar adequadamente o conjunto de informações disponível, ele tende a apoiar sua decisão em sinais parciais, como indicadores isolados, notícias recentes ou listas resumidas de ativos. Ademais, Amorim et al. (2018) associam maior literacia financeira à construção de carteiras mais ajustadas, o que permite inferir que, na ausência dessa base, a escolha tende a ser menos estruturada. Paralelamente, Barbosa (2022) enfatiza que a falta de domínio técnico amplia a dependência de terceiros e de análises prontas, reduzindo a autonomia do investidor e elevando a probabilidade de decisões pouco fundamentadas.

Adicionalmente, a repetição de decisões sob alta exigência analítica pode reduzir a consistência do julgamento. Conseqüentemente, o investidor que precisa filtrar ativos, interpretar fundamentos, acompanhar resultados corporativos e revisar sua carteira em ambientes fragmentados tende a operar sob maior desgaste cognitivo. Ademais, ANBIMA (2022) mostra que a insuficiência de educação financeira não é problema residual, mas estrutural, o que significa que parte expressiva dos indivíduos ingressa no mercado sem instrumentos adequados para lidar com a densidade informacional disponível. Portanto, a redução da qualidade decisória pode decorrer menos da ausência de dados e mais da incapacidade prática de organizá-los em raciocínio analítico coerente.



No universo das estratégias de dividendos, essa limitação assume implicações adicionais. Consequentemente, a seleção de ativos com foco em proventos exige leitura integrada de dividend yield, payout, lucratividade, fluxo de caixa, estrutura de capital e regularidade histórica da distribuição. Ademais, Holanda e Coelho (2012) demonstram que a política de dividendos possui relevância na dinâmica do mercado brasileiro, enquanto Silva e Carvalho (2020) apontam que o dividend yield pode estar associado a comportamentos específicos de retorno no mercado nacional. Paralelamente, Suno Research (2023) destaca que a análise do payout requer interpretação conjunta da política de distribuição e da capacidade de sustentação operacional da empresa. Portanto, o investidor que pretende adotar estratégia orientada a dividendos precisa ir além da observação pontual do rendimento corrente, o que aumenta a exigência cognitiva quando as informações permanecem dispersas e sem estrutura interpretativa.

2.2 Modelos de Linguagem como Próteses Cognitivas

A digitalização do mercado financeiro ampliou substancialmente o volume de dados acessíveis ao investidor, mas não eliminou a dificuldade de transformar essa informação bruta em conhecimento utilizável. O desafio contemporâneo deslocou-se da escassez para a urgência de organizar e interpretar bases extensas e heterogêneas. Hinfor (2024) assinala que a inteligência artificial vem sendo incorporada à análise de ativos justamente para sanar essa deficiência analítica, indicando uma mudança profunda na mediação entre o usuário e o mercado. Plataformas tradicionais já começaram a empregar IA para traduzir dúvidas comuns em parâmetros técnicos, sinalizando a viabilidade operacional e a aceitação dessa tecnologia (Infomoney, 2024).

Nesse contexto, os modelos de linguagem atuam como verdadeiros recursos de apoio à cognição. Sua função transcende a simples geração textual, envolvendo a reorganização de consultas, a síntese de dados dispersos e a redução do número de cliques exigidos para se chegar a uma resposta final. Ao converter linguagem natural em rotinas estruturadas de busca e cálculo algorítmico, o sistema poupa o investidor de dominar previamente a arquitetura das corretoras ou a nomenclatura técnica dos indicadores. A grande utilidade desses modelos reside, portanto, na capacidade de traduzir a intenção do usuário na complexidade matemática da base de dados financeira.

Sob essa perspectiva, a principal contribuição dos modelos de linguagem para o contexto de investimentos reside na estruturação do raciocínio analítico. Consequentemente,

consultas formuladas em termos cotidianos, como a apuração de dividendos acumulados desde a compra de um ativo ou a comparação entre papéis de diferentes setores, podem ser convertidas em sequências lógicas de processamento. Ademais, Martins e Pontes (2022), ao sistematizarem critérios de seleção de ações voltadas a dividendos, evidenciam que a análise desse tipo de ativo depende de organização metodológica, uso disciplinado de indicadores e comparação histórica. Portanto, quando um modelo de linguagem operacionaliza esses critérios em linguagem natural, ele reduz a distância entre a formulação da dúvida e a execução técnica da análise.

Paralelamente, o uso desses sistemas em finanças depende da qualidade das fontes de dados e da capacidade de rastrear as etapas do processamento. Consequentemente, Medeiros et al. (2023) reforçam que a qualidade da informação contábil afeta a avaliação de risco no mercado, o que torna necessário que sistemas baseados em IA se apoiem em bases confiáveis e auditáveis. Ademais, Ventura et al. (2023) demonstram que a qualidade do reporte financeiro está vinculada a mecanismos institucionais de governança, o que reforça a importância de integrar o modelo de linguagem a dados formais e verificáveis. Portanto, a utilidade analítica da IA não pode ser dissociada de critérios de confiabilidade, atualização e consistência da informação processada.

Nesse sentido, a aplicação de modelos de linguagem ao apoio ao investidor requer contenção de riscos operacionais e semânticos. Consequentemente, Scalzer e Souza (2021) mostram que a informatividade dos resultados no mercado brasileiro é sensível a variáveis relacionadas a dividendos e restrições financeiras, o que indica que interpretações simplificadas ou descontextualizadas podem comprometer a leitura dos fundamentos. Ademais, a utilização de IA em ambientes financeiros exige delimitação clara das tarefas do sistema, validação dos cálculos apresentados e restrição de respostas que ultrapassem a base efetivamente consultada. Portanto, a arquitetura de apoio deve privilegiar perguntas objetivas, conexão com fontes externas e mecanismos que permitam ao usuário compreender como a resposta foi construída.

Adicionalmente, o potencial desses modelos é ampliado quando a resposta devolvida reduz dispersão informacional e favorece compreensão incremental. Consequentemente, ao organizar a saída por ativo, período, indicador e fonte, a IA diminui a necessidade de busca fragmentada e de cálculo manual pelo usuário. Ademais, Barbosa (2022) e Wisniewski (2011) indicam que boa parte das dificuldades do investidor brasileiro está associada justamente à ausência de domínio técnico para interpretar e consolidar informações financeiras. Portanto, sistemas que entregam respostas estruturadas em linguagem natural podem cumprir função educacional e instrumental ao mesmo tempo, desde que não substituam a responsabilidade final

da decisão.

Portanto, os modelos de linguagem podem ser entendidos como mecanismos de compressão e reorganização da informação financeira. Consequentemente, sua aplicação ao universo de dividendos permite condensar histórico de proventos, fundamentos corporativos e métricas derivadas em saídas textuais mais compatíveis com os limites de atenção e processamento do investidor. Ademais, essa função está alinhada ao objetivo de reduzir a carga cognitiva extrínseca envolvida no uso de plataformas tradicionais, sem eliminar a necessidade de julgamento humano sobre risco, horizonte de investimento e adequação da estratégia à situação do usuário.

3 PROCEDIMENTOS METODOLÓGICOS

A natureza do problema investigado exige uma abordagem voltada à proposição de uma solução sociotécnica, indo além da mera descrição fenomenológica. Por essa razão, o estudo adota uma pesquisa qualitativa e aplicada, com orientação metodológica ancorada na Design Science Research (DSR), ideal para a concepção de artefatos científicos voltados à resolução de problemas práticos no mercado de capitais.

Esse enquadramento permitiu estruturar a pesquisa em quatro etapas centrais. Inicialmente, realizou-se a delimitação do diagnóstico prático, associando o crescimento de investidores pessoa física à persistência da sobrecarga cognitiva no uso de plataformas tradicionais. Em seguida, procedeu-se ao levantamento teórico cruzando a Teoria da Carga Cognitiva, Finanças Comportamentais e sistemas baseados em LLMs (Large Language Models).

A terceira etapa concentrou-se na ideação do artefato tecnológico em si. A Carteira Inteligente IA foi concebida como um modelo GPT configurado por prompts especializados e integrado a APIs externas para consumo de dados sob demanda. Nesse desenho, a ferramenta foi idealizada para dialogar em linguagem natural, interpretar comandos sobre ativos de dividendos e executar rotinas de cálculo. A arquitetura prevê ainda a restrição do escopo de resposta a parâmetros estritamente analíticos, evitando atuar como casa de análise (research) ou emitir recomendações diretas de compra ou venda.

No plano técnico, a solução foi modelada para consumir dados do provedor Yahoo Finance via RapidAPI. Foram definidos endpoints específicos como `getStockSummary`, `getDividendHistory` e `getFinancials` para a recuperação de cotações, histórico de proventos e demonstrações financeiras. Essa configuração busca assegurar a atualização em tempo real, a

rastreabilidade da origem dos dados e a auditabilidade dos cálculos apresentados.

Por fim, a etapa analítica consistiu na avaliação conceitual do artefato a partir de sua capacidade de mitigar a carga cognitiva extrínseca. A discussão dos resultados foi construída com base na lógica de redução de etapas operacionais e na substituição da navegação fragmentada por interações conversacionais centralizadas, não se apoiando, neste estágio preliminar, em testes experimentais com amostras de usuários, mas sim na consistência da proposição arquitetural.

4 DISCUSSÃO E ANÁLISE DOS DADOS

A proposição da Carteira Inteligente IA parte da premissa de que o principal obstáculo para o investidor pessoa física não é a falta de dados, mas a exigência de processá-los sob severas restrições cognitivas. Para solucionar essa dor de mercado, o artefato foi desenhado para eliminar etapas exaustivas de navegação, filtragem e correlação manual entre múltiplas fontes. Sua lógica operacional ancora-se em três funções principais: coleta de dados financeiros externos (via API), processamento interno de métricas contábeis e apresentação textual estruturada.

Nesse arranjo inovador, a interação em linguagem natural substitui a obrigação de o usuário traduzir sua intenção analítica em cliques ou filtros matemáticos. A pergunta formulada passa a ser tratada pelo algoritmo como uma unidade semântica completa. Essa dinâmica inverte a lógica tradicional das plataformas financeiras ao deslocar grande parte do esforço de processamento mental humano para o sistema, materializando na prática a noção de "prótese cognitiva" debatida na fundamentação teórica.

Tabela 1: Exemplos de consultas em linguagem natural na Carteira Inteligente IA

Consulta do usuário	Resposta estruturada esperada
“Comprei 400 ações de ABEV3.SA a R\$ 14,50 em 12/04/2021 e 250 ações de ENBR3.SA a R\$ 18,20 em 20/06/2022. Traga o histórico de dividendos pagos por cada ativo desde a data de compra e calcule o dividend yield acumulado para cada um.”	ABEV3: dividendos acumulados de R\$ 3,203 por ação, yield acumulado de 22,1%. ENBR3: dividendos acumulados de R\$ 4,614 por ação, yield acumulado de 25,3%.
“Comprei 200 ações de PETR4.SA a R\$ 27,40 em 05/07/2022 e 150 ações de TAEE11.SA a R\$ 37,00 em 10/02/2023. Traga o histórico de	PETR4: dividendos acumulados de R\$ 12,713 por ação, yield acumulado de 46,4%. TAEE11: dividendos acumulados de R\$ 6,993 por ação,



dividendos desde a compra e calcule o dividendo yield acumulado.”

“Comprei 500 ações de ITSA4.SA a R\$ 8,20 em 10/01/2023 e 300 ações de BBAS3.SA a R\$ 45,50 em 15/03/2023. Considerando dividendos pagos e preços atuais, quais foram meus ganhos totais?”

yield acumulado de 18,9%.

ITSA4: preço atual, dividendos por ação e ganho total. BBAS3: preço atual, dividendos por ação e resultado total. Consolidação do saldo final da carteira.

Fonte: Elaborado pelo autor (2026).

Os exemplos da Tabela 1 ilustram uma mudança radical na unidade operacional da tarefa analítica. Uma única entrada textual passa a condensar dados de compra, quantidades, datas, ticker e o objetivo macro da análise. Em plataformas financeiras convencionais, essa mesma tarefa exigiria múltiplos cliques: acessar o histórico de proventos em uma tela, cruzar com a cotação atual em outra, resgatar o preço médio de aquisição e, muitas vezes, recorrer a planilhas em Excel para apurar o cálculo acumulado. Logo, a IA reduz a necessidade de o usuário fatiar o problema em subtarefas exaustivas.

Sob a lente da carga cognitiva, essa alteração incide diretamente na redução da carga extrínseca. O investidor é poupado de alocar recursos mentais para mapear onde cada dado está escondido na interface ou como alinhar informações de períodos cronológicos distintos. Como a resposta estruturada já retorna agrupada por ativo, métrica e horizonte temporal, o esforço de retenção na memória de trabalho cai drasticamente. A interface conversacional, portanto, não simplifica a complexidade matemática do mercado, mas otimiza a forma como ela é digerida pelo cérebro humano.

De forma subjacente, esse modelo conversacional atua diretamente sobre os vieses comportamentais. Ao receber uma síntese imparcial baseada em regras explícitas e métricas reprodutíveis, o investidor fica menos suscetível a heurísticas de disponibilidade (como escolher uma ação só porque seu nome circulou no noticiário recente). A ancoragem do resultado no histórico consolidado de proventos desvia a atenção da volatilidade diária do preço, incentivando uma postura menos impulsiva e mais aderente à estratégia de dividendos no longo prazo.

Nesse contexto, a contribuição do artefato pode ser melhor compreendida quando comparada a soluções já presentes no mercado. Consequentemente, a Tabela 2 sintetiza diferenças entre plataformas consolidadas e a lógica conversacional proposta.

Tabela 2: Comparativo entre a Carteira Inteligente IA e soluções existentes

Plataforma	Função principal	Exigência cognitiva do usuário	Lógica de interação
Status Invest	Indicadores de ações, agenda de proventos, simuladores	Necessidade de navegar entre páginas, comparar indicadores e interpretar múltiplas seções	Navegação por menus e painéis
TradeMap	Consolidação de carteira, proventos e relatórios	Necessidade de localizar eventos, conciliar dados da carteira e interpretar visualizações distintas	Interface gráfica com módulos separados
Comdinheiro	Análise fundamentalista e triagem de ativos	Necessidade de parametrizar filtros, ler bases extensas e correlacionar saídas analíticas	Screeners técnicos e relatórios
Fundamentus	Consulta rápida de indicadores fundamentalistas	Necessidade de interpretação autônoma de múltiplos e comparação manual entre empresas	Listagem tabular de indicadores
Carteira Inteligente IA	Consulta conversacional com cálculo e síntese de dividendos	Redução do esforço de navegação e da necessidade de integrar dados manualmente	Linguagem natural com resposta estruturada

Fonte: Elaborado pelo autor (2026).

O contraste apresentado na Tabela 2 evidencia que o diferencial tecnológico da proposta não está em criar uma nova base de dados de mercado, mas em revolucionar o acesso a ela. Plataformas como Status Invest, TradeMap, Comdinheiro e Fundamentus oferecem inegável amplitude informacional; contudo, pressupõem que o usuário já saiba localizar, ponderar e correlacionar dezenas de elementos espalhados por interfaces distintas. Embora esse modelo clássico de painel (dashboard) seja funcional para profissionais com literacia financeira avançada, ele impõe um custo cognitivo frequentemente paralisante ao investidor iniciante ou intermediário.

Sob essa ótica, a Carteira Inteligente IA atua primariamente como uma camada de unificação semântica. A pergunta em texto livre funciona como um gatilho único para que a máquina encadeie consultas internas, recupere cotações, aplique fórmulas matemáticas e roteirize a resposta. Essa unificação reduz drasticamente as transições atencionais do olho humano entre gráficos e elimina a comparação paralela de telas. O ganho principal do artefato, portanto, concentra-se na drástica economia de energia mental, entregando muito mais do que

uma mera automação de cálculos de dividendos.

Adicionalmente, a arquitetura proposta preserva consistência metodológica ao restringir a análise a parâmetros vinculados à estratégia de dividendos. Consequentemente, indicadores como payout, dividend yield, retorno sobre patrimônio líquido, fluxo de caixa operacional e endividamento podem ser mobilizados em lógica comparável e rastreável. Ademais, a integração com APIs externas permite que a resposta seja ancorada em dados auditáveis, reduzindo a dependência de textos genéricos ou de inferências não verificáveis. Portanto, a mediação cognitiva só se sustenta se estiver conectada à precisão informacional.

No plano funcional, a ferramenta também foi concebida com possibilidade de expansão para gestão patrimonial mais ampla. Consequentemente, a arquitetura admite acoplamento de módulos voltados à coleta estruturada de dados, geração de painéis e encaminhamento para suporte humano especializado. Ademais, essas extensões indicam que a lógica de redução da carga cognitiva pode ir além da consulta de dividendos, alcançando a organização do patrimônio em sentido mais abrangente.

Tabela 3: Possibilidades de expansão funcional da Carteira Inteligente IA

Etapa de expansão	Descrição funcional	Tecnologia associada	Efeito esperado sobre a cognição do usuário
Chatbot de coleta patrimonial	Registro de ativos financeiros e não financeiros em linguagem natural	LLM, formulários dinâmicos e APIs	Redução do esforço de inserção e organização inicial dos dados
Geração dinâmica de dashboards	Painéis com liquidez, concentração, proventos e composição patrimonial	BI integrado via API	Conversão de bases dispersas em visualização consolidada
Detecção de anomalias	Identificação de padrões atípicos na carteira	Modelos estatísticos e machine learning	Apoio à atenção seletiva sobre eventos relevantes
Sugestões matemáticas parametrizadas	Simulações de rebalanceamento e distribuição	LLM com regras e base de dados integrada	Redução do esforço de cálculo exploratório
Atendimento híbrido com analista CEA	Encaminhamento de relatórios para profissional certificado	Integração chatbot, CRM e comunicação segura	Complementação da IA com revisão humana especializada

Fonte: Elaborado pelo autor (2026).

As expansões listadas na Tabela 3 ampliam o alcance da proposta sem alterar sua premissa central. Consequentemente, a função da tecnologia continua sendo reduzir fricção cognitiva entre dado e decisão. Ademais, a inclusão de chatbot de coleta patrimonial e



dashboards dinâmicos permite consolidar informações que, em cenários usuais, permanecem dispersas entre extratos, corretoras e registros pessoais. Portanto, o sistema passa a atuar não apenas na análise pontual de ativos, mas também na organização da base sobre a qual novas decisões serão tomadas.

Paralelamente, a previsão de atendimento híbrido com analista certificado introduz mecanismo de contenção de risco interpretativo. Conseqüentemente, a IA pode operar como primeira camada de estruturação e triagem, enquanto a análise profissional humana absorve casos que exigem contextualização normativa, patrimonial ou tributária. Ademais, essa lógica é coerente com o princípio de human in the loop, relevante em sistemas financeiros que operam com impacto potencial sobre decisões patrimoniais.

No entanto, a mitigação da carga cognitiva não implica eliminação total do risco decisório. Conseqüentemente, a ferramenta pode reduzir ruído e organizar dados, mas não suprime incerteza de mercado, viés do usuário ou limitação das bases de origem. Ademais, a dependência de APIs de terceiros, especialmente em planos gratuitos, introduz risco de indisponibilidade, latência e inconsistência temporal. Portanto, a confiabilidade da prótese cognitiva depende tanto da qualidade da interface quanto da robustez do ecossistema de dados ao qual ela se conecta.

Adicionalmente, modelos de linguagem permanecem sujeitos a alucinações e desvios semânticos. Conseqüentemente, mesmo quando integrados a bases externas, esses sistemas exigem prompts restritivos, rotinas de verificação e delimitação do escopo de resposta. Ademais, consultas vagas, ambíguas ou excessivamente abertas podem ampliar a possibilidade de saídas menos consistentes. Portanto, a redução de carga cognitiva precisa ser acompanhada de mecanismos de governança informacional.

Em síntese, os resultados discutidos indicam que a Carteira Inteligente IA reorganiza o processo analítico do investidor em três dimensões. Conseqüentemente, ela comprime etapas operacionais, unifica dados dispersos e entrega uma narrativa quantitativa orientada à pergunta do usuário. Ademais, essa estrutura contribui para reduzir fadiga decisória e dependência de atalhos heurísticos ao deslocar parte do esforço de integração para o sistema. Portanto, a ferramenta se apresenta como artefato compatível com a lente da carga cognitiva e com a agenda aplicada das Finanças Comportamentais.

5 CONCLUSÕES

A expansão do acesso ao mercado de capitais evidenciou o grave descompasso entre a vasta disponibilidade de informação e a real capacidade humana de processá-la. O investidor



pessoa física passou a operar em um ambiente de alta densidade informacional, no qual a abundância de telas, filtros e indicadores não se traduz, necessariamente, em maior compreensão analítica. Essa condição reforça a urgência por soluções tecnológicas desenhadas primariamente com foco nos limites da cognição humana.

Nesse contexto, este artigo propôs a arquitetura da Carteira Inteligente IA, articulando a Teoria da Carga Cognitiva, as Finanças Comportamentais e os modelos de linguagem integrados a APIs financeiras externas. O estudo demonstrou que a IA possui o potencial técnico para atuar como uma verdadeira prótese cognitiva, convertendo consultas complexas em linguagem natural em respostas estruturadas, rastreáveis e metodologicamente delimitadas.

Ademais, a proposta foi posicionada como mecanismo de redução de ruído visual, de compressão informacional e de apoio à interpretação de estratégias voltadas a dividendos. Já sob a ótica teórica, a principal contribuição do trabalho está em aproximar duas agendas que usualmente aparecem dissociadas. Consequentemente, a análise de investimentos deixou de ser tratada apenas como questão de acesso a dados ou domínio técnico e passou a ser examinada também como problema de carga cognitiva e vulnerabilidade comportamental. Ademais, essa articulação permite compreender por que investidores expostos a interfaces extensas podem recorrer a heurísticas e apresentar fadiga decisória, mesmo quando a informação necessária está publicamente disponível.

No plano aplicado, a arquitetura proposta demonstra viabilidade conceitual para reduzir o esgotamento analítico em tarefas relacionadas a dividendos. Consequentemente, a centralização conversacional de consultas como histórico de proventos, cálculo de yield acumulado e comparação entre ativos substitui a navegação fragmentada em múltiplas abas. Ademais, a integração com dados do Yahoo Finance via RapidAPI e a parametrização de indicadores como payout e dividend yield conferem base operacional ao artefato delineado.

Contudo, o estudo apresenta limitações que devem ser explicitadas. Consequentemente, a dependência de APIs de terceiros pode comprometer estabilidade, cobertura e atualização dos dados. Ademais, o uso de modelos de linguagem impõe risco de alucinações, inconsistências textuais e necessidade de validação contínua das respostas geradas. Paralelamente, a presente pesquisa descreve e fundamenta a arquitetura, mas não substitui etapas futuras de validação empírica com usuários reais em contextos experimentais ou de campo.

Diante disso, pesquisas futuras podem avançar em três direções complementares. Consequentemente, recomenda-se a realização de testes com investidores para medir redução de tempo de busca, variação de carga cognitiva percebida e precisão interpretativa antes e

depois do uso da ferramenta. Ademais, sugere-se ampliar o escopo para fundos imobiliários, ETFs e métricas ESG, bem como implementar redundância de fontes de dados e rotinas automáticas de checagem. Portanto, a Carteira Inteligente IA se consolida, neste estágio, como proposição arquitetural orientada ao princípio de que a tecnologia de apoio à decisão financeira deve ser desenhada em função das limitações cognitivas humanas e não apenas da capacidade de processamento computacional.

REFERÊNCIAS

Amorim, K. A. F., Lucena, G. K. F., Girão, L. F. A. P., & Queiroz, D. B. (2018). A influência da educação financeira na inserção dos investidores no mercado de capitais brasileiro: um estudo com discentes da área de negócios. *RACE: Revista de Administração, Contabilidade e Economia*, 17(2), 507–534. <https://doi.org/10.18593/RACE.V17I2.16834>

ANBIMA. (2022). *Relatório mapa de iniciativas de educação financeira*. https://www.anbima.com.br/data/files/9B/54/F2/61/48B5791010999579B82BA2A8/relatorio_ANBIMA_mapa_iniciativas_educacao_financeira.pdf

ANBIMA. (2024). *Investimentos dos brasileiros crescem 6,1% e chegam a R\$ 6,8 trilhões no primeiro trimestre de 2024*. https://www.anbima.com.br/pt_br/noticias/investimentos-dos-brasileiros-crescem-6-1-e-chegam-a-r-6-8-trilhoes-no-primeiro-trimestre-de-2024.htm

B3. (2024a). *Número de pessoas físicas na B3*. https://www.b3.com.br/pt_br/noticias/pessoas-fisicas-na-b3.htm

B3. (2025). *Renda fixa cresce 20% no segundo trimestre de 2025, com mais de 100 milhões de investidores*. https://www.b3.com.br/pt_br/noticias/renda-fixa-cresce-20-no-segundo-trimestre-de-2025-com-mais-de-100-milhoes-de-investidores.htm

Barbosa, J. F. (2022). *A importância da educação financeira para os novos investidores pessoa física na bolsa de valores do Brasil* [Dissertação de mestrado, Universidade Federal de Alagoas].

Repositório

UFAL.

<https://www.repositorio.ufal.br/bitstream/123456789/13667/1/A%20import%C3%A2ncia%20da%20educa%C3%A7%C3%A3o%20financeira%20para%20os%20novos%20investidores%20pessoa%20f%C3%ADsica%20na%20bolsa%20de%20valores%20do%20Brasil.pdf>

Hinfor. (2024). *Como a inteligência artificial está revolucionando a análise de ativos.*

<https://hinfor.com.br/ia-revolucionando-analise-de-ativos/>

Holanda, A. P., & Coelho, A. C. D. (2012). Dividends and clientele effect: Evidence in the Brazilian market. *RAE Revista de Administração de Empresas*, 52(4), 448–463.

<https://doi.org/10.1590/S0034-75902012000400007>

Infomoney. (2020). *Investidores que moram no interior ganham espaço na B3.*

<https://www.infomoney.com.br/mercados/investidores-que-moram-no-interior-ganham-espaco-na-b3/>

Infomoney. (2023). *Dividend yield: o que é e como usar.*

<https://www.infomoney.com.br/guias/dividend-yield/>

Infomoney. (2024). *Comdinheiro inova e implementa IA em sua plataforma.*

<https://www.infomoney.com.br/onde-investir/comdinheiro-inova-e-implementa-ia-em-sua-plataforma/>

Machado, J. P. (2023). *Educação financeira e participação regional no mercado de capitais brasileiro* [Monografia de graduação, Pontifícia Universidade Católica de Goiás].

https://repositorio.pucgoias.edu.br/jspui/bitstream/123456789/6101/1/Mono%20finalizada_Ju_railde.pdf

Marques, B. S., Perpétuo, A. A. G., & Rocha, D. M. (2020). Análise bibliométrica sobre os estudos de dividendos no Brasil. *Research, Society and Development*, 9(8), e159985658.

<https://doi.org/10.33448/RSD-V9I8.565>

Martins, O., & Pontes, F. (2022). *O investidor em ações de dividendos*. Ed. do Autor.

Mato Grosso Econômico. (2024). *Maioria na região Centro Oeste admite entender pouco de educação financeira.*

<https://matogrossoeconomico.com.br/economia/maioria-na-regiao-centro-oeste-admite-entender-pouco-de-educacao-financeira/>

Medeiros, J. T., Vasconcelos, A. C., & De Luca, M. M. M. (2023). Qualidade das informações contábeis e risco sistemático no mercado acionário brasileiro. *Revista Catarinense da Ciência Contábil*, 22(1), 1–18. <https://doi.org/10.16930/2237-7662202333571>

Poder360. (2023). *Número de investidores na B3 cai pela 1ª vez em 7 anos.*

<https://www.poder360.com.br/economia/numero-de-investidores-na-b3-cai-pela-1a-vez-em-7-anos/>

Scalzer, R. S., & Souza, A. C. S. (2021). Earnings informativeness in the Brazilian market: The influence of dividends and financial constraints. *The Investment Analysts Journal*, 50(4), 287–302. <https://doi.org/10.1080/10293523.2021.1991129>

Silva, R. F., & Carvalho, A. G. (2020). Dividend yield e retornos anormais no mercado brasileiro. *Revista Linceu On Line*, 10(2), 55–72. https://liceu.fecap.br/LICEU_ON-LINE/article/download/1891/1170

Suno Research. (2023). *Payout: entenda o que é e como analisar*. <https://www.suno.com.br/artigos/payout/>

Ventura, A. F. A., Figueiredo, J., Ventura Júnior, R., Teixeira, B. M., & Macagnan, C. B. (2023). Determining factors of the quality of the financial reporting of the banking companies listed in Brazil Bolsa Balcão B3. *Cuadernos de Contabilidad*, 24(1). <https://doi.org/10.11144/javeriana.cc24.dfqf>

Wisniewski, M. L. G. (2011). A importância da educação financeira na gestão das finanças pessoais: Uma ênfase na popularização do mercado de capitais brasileiro. *Intersaberes*, 6(11), 79–97. <https://doi.org/10.22169/revint.v6i11.32>