

Xtract: Um Plug-in Baseado em IA para Recomendações Explicáveis da Refatoração Extract Method

Guisella Angulo Armijo
Departamento de Computação,
UFSCar
São Carlos, Brasil
angulogc@gmail.com

Igor Ueno
Departamento de Computação,
UFSCar
São Carlos, Brasil
igorueno@estudante.ufscar.br

Valter Vieira de Camargo
Departamento de Computação,
UFSCar
São Carlos, Brasil
valtervcamargo@ufscar.br

Resumo

A evolução dos sistemas de software aumenta gradativamente sua complexidade, tornando a refatoração uma tarefa essencial para manter a qualidade do código. Isso demanda a aplicação contínua de refatorações. Entretanto, a identificação manual de oportunidades de refatoração é uma tarefa complexa, e as ferramentas automáticas disponíveis costumam gerar extensas listas de recomendações incompletas ou pouco compreensíveis, resultando em baixa aceitação por parte dos desenvolvedores. Neste contexto, este trabalho introduz **Xtract**, um plug-in de recomendação integrado ao IntelliJ IDEA, projetado para gerar recomendações de *Extract Method* orientadas pelo critério W3B (Which, Where, Why e Benefits). O **Xtract** emprega um pipeline modular que combina a extração de métricas estruturais e de fragmentos de código, a classificação por meio do modelo Random Forest, a análise semântica utilizando o modelo pré-treinado CodeBERT, um Explicador Consensual baseado em IA Explicável (XAI) e o uso da LLM GPT-4 para estruturar a Recomendação. Em termos de uso, a ferramenta processa um método Java selecionado pelo desenvolvedor e apresenta uma recomendação contendo o fragmento de código sugerido para extração, o score de extração calculado pelo CodeBERT, acompanhado de uma explicação baseada em *features* (ranking de métricas), além de uma explicação em linguagem natural. Embora a abordagem subjacente contemple também a dimensão Benefits, esta não é apresentada na interface da versão do plug-in descrita neste artigo. Dessa forma, o **Xtract** busca aumentar a confiança e a aceitação dos desenvolvedores em relação às ferramentas de recomendação de refatoração.

Demo de vídeo: <https://doi.org/10.5281/zenodo.21459888>

Palavras-chave

recomendações de refatoração, aprendizado de máquina, IA explicável

1 Introdução

À medida que os sistemas de software evoluem, eles inevitavelmente acumulam complexidade e sofrem degradação de qualidade [25]. De acordo com a primeira lei de Lehman, os sistemas devem ser continuamente adaptados, ou tornam-se progressivamente menos satisfatórios [23]. Para mitigar essa degradação, a refatoração é adotada como uma prática disciplinada para combater a erosão do design e apoiar a manutenção.

A refatoração, popularizada por Fowler em 1999 [15], consiste em modificar um sistema de software sem alterar seu comportamento externo, enquanto melhora sua estrutura interna. Ela ajuda a prevenir a degradação de design, reduz a propensão a erros e melhora a legibilidade e a manutenibilidade do código. Apesar

desses benefícios, identificar quando e como refatorar ainda é um desafio, particularmente em sistemas grandes e complexos. Tradicionalmente, esse processo depende fortemente da experiência e intuição dos desenvolvedores, frequentemente apoiado por code smells como indicadores de possíveis problemas [15].

Extract Method é uma das refatorações amplamente adotadas no desenvolvimento de software, pois decompõe métodos grandes e complexos, abordando problemas como *Duplicated code*, *Long Method* e *Feature Envy* [4, 8, 20, 30, 39]. Em linhas gerais, essa refatoração envolve três etapas principais: i) identificar o método candidato, isto é, um método que apresenta algum sinal de problemas de manutenção; ii) identificar o trecho candidato a ser extraído do método original; iii) criar um novo método com o trecho extraído e substituir o trecho original por uma chamado ao novo método.

Existem diversas ferramentas automatizadas que oferecem a identificação de oportunidades para a aplicação da refatoração *Extract Method*, visto que a detecção manual é propensa a erros e é uma tarefa muito demorada. Essas ferramentas utilizam diversas técnicas, tais como: heurísticas e padrões estruturais [14, 35]; abordagens baseadas em busca, utilizando estratégias de otimização para equilibrar múltiplas métricas de qualidade [2, 28]; e mais recentemente, técnicas de aprendizado de máquina, explorando métricas de código-fonte e dados históricos para identificar oportunidades de refatoração [20, 22, 24, 40].

Apesar desses avanços, as recomendações frequentemente são incompletas; isto é, podem indicar a presença de um problema, mas falham em especificar qual refatoração aplicar, onde no código ela deve ser realizada, por que é recomendada ou quais benefícios traria. Como resultado, os desenvolvedores ficam com informações parciais, limitando sua capacidade de compreender, confiar e agir efetivamente sobre a recomendação. Além disso, um problema enfrentado pelas ferramentas que recomendam **Extract Method** é o fato de estarem atreladas a *code smells*, tornando a recomendação ainda mais restritiva.

Este trabalho apresenta um plug-in baseado em IA, denominado **Xtract**, projetado para gerar recomendações de refatoração *Extract Method*. O **Xtract**, implementado como um plug-in para IntelliJ, orientado pelo critério W3B (Which, Where, Why e Benefits) [7] para definir a completude da recomendação em termos de: qual refatoração aplicar, onde no código ela deve ser realizada, por que ela é sugerida e quais benefícios ela proporciona. Seu núcleo integra técnicas de aprendizado de máquina a mecanismos de explicabilidade baseados em *features* e em linguagem natural, utilizando o modelo GPT-4, com o objetivo de produzir recomendações que vão além da simples detecção de oportunidades de refatoração, apoiando explicitamente a compreensão e a tomada de decisão dos desenvolvedores.

A abordagem subjacente ao Xtract contempla as quatro dimensões do critério W3B. Entretanto, por questões de espaço e de projeto da interface do usuário, a versão do plug-in apresentada neste artigo exibe apenas as dimensões *Which*, *Where* e *Why*.

2 Fundamentação Teórica

2.1 Refatoração de Software e Code Smell

Refatoração é o processo de modificar um sistema de software sem alterar seu comportamento externo, visando melhorar sua estrutura interna [15, 29]. As técnicas de refatoração podem ser manuais, semi-automáticas ou automatizadas [3, 25]. Entretanto, a identificação manual de oportunidades de refatoração é uma tarefa trabalhosa e dependente da experiência do desenvolvedor [33].

Nesse contexto, *code smells* têm sido amplamente utilizados como indicadores de possíveis problemas de design e oportunidades de refatoração. Segundo Fowler, um *code smell* representa um indicio superficial de problemas mais profundos no software [15]. Apesar de sua relevância, os *code smells* representam apenas parte das motivações para refatoração [10]. Estudos mostram que refatorações como *Extract Method* também podem ser motivadas por fatores como melhoria de legibilidade, modularização, remoção de duplicação, correção de bugs e otimização de desempenho [19].

2.2 Machine Learning

Aprendizado de Máquina permite que sistemas aprendam padrões a partir de dados e melhorem seu desempenho ao longo do tempo [26]. Entre os principais paradigmas estão o aprendizado supervisionado, utilizado em tarefas de classificação e regressão, e o aprendizado não supervisionado, voltado para a descoberta de padrões e agrupamentos [21, 27]. Redes neurais artificiais e técnicas de *Deep Learning* ampliaram a capacidade dos modelos em capturar relações complexas e não lineares [34].

Mais recentemente, Modelos de Linguagem de Grande Porte (LLMs) e Modelos de Linguagem Pré-treinados (PLMs) passaram a desempenhar papel importante em tarefas de engenharia de software. Baseados na arquitetura Transformer [38], esses modelos aprendem representações semânticas e sintáticas a partir de grandes volumes de dados. Modelos como BERT [12] e CodeBERT [13] demonstraram resultados promissores em tarefas relacionadas a código-fonte, incluindo classificação, sumarização, busca de código e recomendação de refatorações. Em especial, o CodeBERT combina código-fonte e linguagem natural durante o pré-treinamento, permitindo análises mais contextualizadas e eficazes para aplicações em engenharia de software.

2.3 Explainable Machine Learning

Com o aumento da complexidade dos modelos de aprendizado de máquina, surge o desafio de equilibrar desempenho e interpretabilidade [18]. Nesse contexto, a Inteligência Artificial Explicável (*Explainable Artificial Intelligence-XAI*) busca tornar as predições dos modelos mais compreensíveis e confiáveis para os usuários [17].

As técnicas de XAI fornecem explicações sobre o comportamento dos modelos, auxiliando na transparência, confiança e interpretabilidade das decisões automatizadas [16]. Essas abordagens podem envolver modelos inerentemente interpretáveis ou métodos *post-hoc*, aplicados após o treinamento do modelo [5] como LIME, SHAP e Anchors, que explicam predições individuais por meio da relevância

de atributos ou regras locais. Além de melhorar a interpretabilidade, XAI também contribui para depuração, validação e identificação de vieses em sistemas de ML, promovendo maior confiabilidade e adoção responsável dessas tecnologias [31].

3 Critério W3B

O critério W3B (*Which*, *Where*, *Why* e *Benefits*) surge como resultado de uma revisão sistemática conduzida com o objetivo de compreender o uso de aprendizado de máquina em recomendações de refatoração [7]. O critério visa avaliar a completude de uma recomendação, considerando como completa aquela que fornece aos desenvolvedores informações suficientes para apoiar a tomada de decisão. Nesse contexto, uma recomendação é considerada completa quando informa: (i) qual refatoração deve ser aplicada, (ii) onde ela deve ser realizada no código-fonte, (iii) por que ela foi recomendada e (iv) quais benefícios sua aplicação pode trazer. A seguir detalhamos cada item do critério.

WHICH: define qual refatoração deve ser aplicada, especificando explicitamente o tipo de refatoração, como *Extract Method*, *Move Method* ou *Rename Method*.

WHERE: identifica onde a refatoração deve ser aplicada, indicando os elementos do código afetados, como classes, métodos, atributos ou trechos específicos de código. Dependendo do tipo de refatoração, o nível de granularidade pode variar. Por exemplo, em *Extract Method*, é necessário identificar tanto o método original quanto o trecho exato de código que deve ser extraído.

WHY: fornece uma explicação sobre por que a refatoração foi recomendada, apresentando os fatores que motivaram a decisão do modelo. Esse aspecto é importante para aumentar a transparência e a confiança nas recomendações, podendo ser apoiado por técnicas de Inteligência Artificial Explicável (XAI) [11].

BENEFITS: descreve os benefícios esperados com a aplicação da refatoração, como melhorias em legibilidade, manutenção, modularidade ou qualidade do software.

4 Xtract Plug-in

4.1 Caso de Uso

A Figura 1 apresenta o principal caso de uso da ferramenta proposta. O desenvolvedor interage diretamente com o plug-in integrado à IDE IntelliJ para identificar oportunidades de refatoração em métodos do projeto local.



Figure 1: Caso de Uso

Nome do Caso de Uso: Identificar Oportunidade de Refatoração.
Objetivo: Auxiliar o desenvolvedor na identificação de oportunidades de refatoração do tipo *Extract Method*, fornecendo recomendações acompanhadas de explicações baseadas no critério W3B diretamente na IDE.

- **Ator Principal:** Desenvolvedor
- **Pré-condição:** O projeto Java deve estar aberto na IDE e conter métodos implementados.
- **Pós-condição:** A ferramenta apresenta uma recomendação de refatoração acompanhada de explicações que justificam a decisão produzida pela abordagem.

4.2 Fluxo sob o Ponto de Vista do Usuário

A utilização da ferramenta ocorre diretamente na IDE IntelliJ, permitindo que o desenvolvedor realize a identificação de oportunidades de refatoração de maneira integrada ao ambiente de desenvolvimento. Figura 2 mostra o fluxo de interação, o qual inicia quando o usuário seleciona o método que deseja analisar no editor de código da IDE. Em seguida, por meio do menu contextual acionado com o clique do botão direito, o usuário executa a opção “*Analysis for Refactoring Opportunities*” e seleciona, no submenu, a opção “*Extract Method*” disponibilizada pelo plug-in.

Após a solicitação, a ferramenta realiza automaticamente o processamento interno do método selecionado. Durante essa etapa, métricas estruturais são extraídas, fragmentos candidatos são identificados e os modelos de aprendizado de máquina analisam o método para verificar sua elegibilidade para refatoração e identificar os trechos mais adequados para extração.




Figure 2: IU- Análise de oportunidades de refatoração

Concluído o processamento, a ferramenta exibe, em uma janela *popup*, o resultado da análise realizada sobre o método, indicando se há necessidade de refatoração e apresentando a probabilidade prevista pelo modelo Random Forest. As Figura 3 ilustra o resultado obtido.

Após a exibição do *popup*, o plug-in destaca o trecho de código recomendado para extração e apresenta os detalhes da recomendação em uma janela lateral expansível. A Figura 4 ilustra uma recomendação gerada para a aplicação da refatoração *Extract Method*.

A recomendação exibida ao desenvolvedor é baseada no critério *W3B* e reúne informações que auxiliam na compreensão do fragmento sugerido para extração, bem como do escore calculado pelo




Figure 3: Xtract - Popup - Resultado da análise do Método

modelo CodeBERT. Dessa forma, o desenvolvedor pode entender não apenas qual fragmento foi selecionado, mas também os fatores que influenciaram a decisão do modelo.

A interface de recomendação é composta pelos seguintes elementos:

- Fragmento recomendado:** o trecho de código sugerido para extração é destacado diretamente no editor. Esse destaque pode ser ativado ou desativado por meio do botão *Hide Recommended Fragment*;
- Escore do fragmento:** a janela lateral apresenta o escore atribuído ao fragmento. O fragmento apresentado é aquele com o maior escore, isto é, é a melhor opção para ser extraído como parte da refatoração *Extract Method*;
- Key Features Influencing the Prediction:** a interface apresenta um ranking das características mais relevantes que influenciaram a predição do modelo, permitindo ao desenvolvedor compreender os principais fatores considerados durante a análise;
- Model Decision Explanation:** a recomendação inclui uma explicação em linguagem natural sobre o raciocínio adotado pelo modelo para gerar a recomendação. Essa explicação é construída a partir das informações extraídas durante a análise, buscando tornar a decisão do modelo mais compreensível e interpretável para o desenvolvedor.

5 Xtract Plug-in Processo Interno

Figura 5 apresenta o plug-in, que está estruturado em duas fases de análise compostas por cinco etapas principais. Primeiramente, dado como entrada o código do método alvo, o componente *Fragment and Metrics Extractor* (FME) obtém métricas de código-fonte e segmenta o método em fragmentos. Em seguida, essas métricas extraídas são utilizadas como entrada para um modelo Random Forest, responsável por prever se o método necessita de refatoração *Extract Method*.

Refactoring Recommendation

The highlighted fragment was classified as the best candidate for Extract Method refactoring, with a prediction probability of 74.02%.

Key Features Influencing the Prediction

Based on a qualitative analysis, the following 5 metrics played a key role in the decision to recommend this method for refactoring. They are listed below in descending order of importance — from the most to the least influential.

Feature	Value
Response For a Class (adapted to method) – number of methods that could be executed in response to a call to this method	28
Lines of Code	88
Number of local variables declared in the method	26
Number of unique identifier tokens used in the method	84
Number of assignment statements in the method	35

Model Decision Explanation

The model recommended refactoring the provided code fragment with a probability of 74.02%. This suggestion is primarily driven by several key metrics that indicate the complexity and potential inefficiencies within the method. The method has a high Response For a Class (RFC) value of 28, meaning it can invoke many other methods, possibly leading to a tightly coupled design. Additionally, the method contains 88 lines of code (LOC), suggesting it is lengthy and potentially difficult to manage. The presence of 26 local variables suggests complexity in data handling, while 84 unique identifier tokens indicate a high level of cognitive load required to understand the method. Furthermore, there are 35 assignment statements, which can contribute to a cluttered and hard-to-read codebase. These factors collectively point towards the need to extract the fragment to improve code organization and potentially reduce the method size, making the code more maintainable and testable.

Figure 4: Xtract - Pipeline

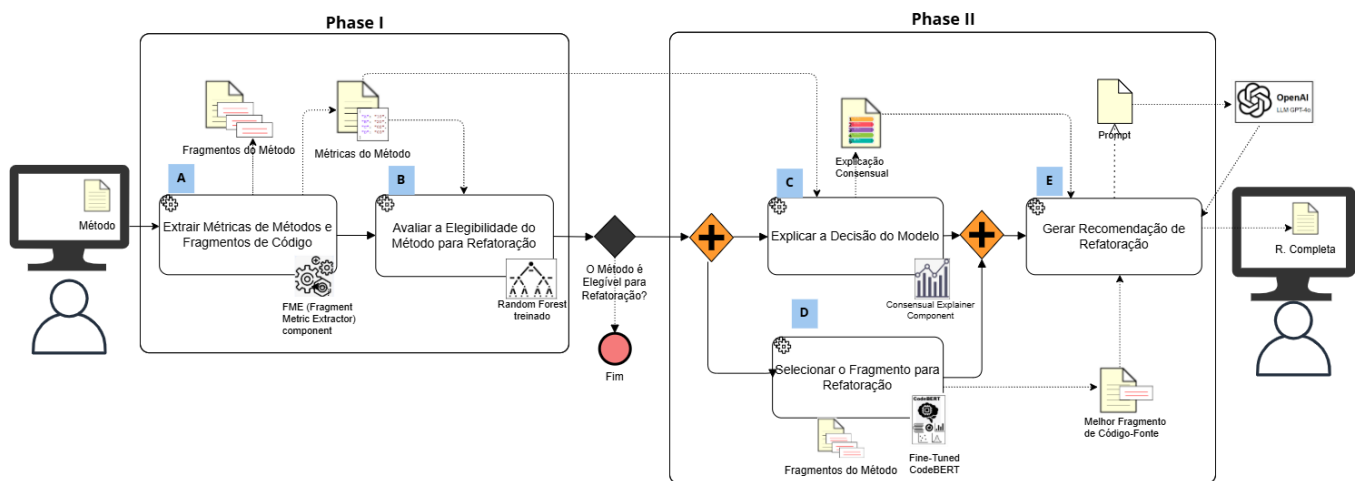


Figure 5: Xtract - Pipeline

Caso a previsão seja positiva, um componente de explicabilidade gera justificativas baseadas nas características mais relevantes para a decisão do modelo. Paralelamente, os fragmentos extraídos são analisados por um modelo CodeBERT treinado (*fine-tuned*), responsável por identificar o fragmento de código mais adequado para extração. Por fim, a recomendação completa é gerada combinando o fragmento selecionado, as explicações produzidas e os elementos do critério W3B. A divisão em duas camadas busca reduzir o custo

computacional da análise. A primeira camada avalia apenas características estruturais do método para decidir se a refatoração deve ser realizada. Já a segunda camada executa uma análise mais detalhada dos fragmentos internos do método, permitindo identificar o trecho mais apropriado para extração e gerar uma recomendação mais precisa e interpretável.

5.1 Fase I

Esta fase corresponde à primeira camada de análise da abordagem e é composta pelas Etapas **A** e **B**. Ela concentra-se exclusivamente na análise em nível de método, considerando apenas métricas estruturais e comportamentais, com o objetivo de determinar se o método deve passar pela refatoração *Extract Method*.

Etapa A: Extração de Métricas e Fragmentos de Código.

Esta etapa é responsável por preparar todas as informações estruturais necessárias para as fases seguintes da abordagem. Como entrada, o componente **FME (Fragment and Metrics Extractor)** recebe o código do método selecionado.

O FME produz dois artefatos: (i) um arquivo CSV contendo 20 métricas estruturais e comportamentais do método e (ii) um arquivo JSON contendo fragmentos candidatos extraídos do método. As métricas são utilizadas posteriormente pela Etapa **B** para avaliar se o método é candidato à refatoração, enquanto os fragmentos extraídos são armazenados para análise posterior na Etapa **D**.

Etapa B: Avaliar a Elegibilidade do Método para Refatoração.

Nesta etapa, um modelo Random Forest (RF) treinado determina se o método analisado é candidato à refatoração *Extract Method*. O modelo Random Forest foi escolhido devido à sua robustez, interpretabilidade e eficiência no tratamento de dados de alta dimensionalidade, características amplamente exploradas em estudos de recomendação de refatoração [8, 9, 30, 37, 40]. O treinamento foi feito utilizando um conjunto de dados (150 mil amostras) contendo métricas estruturais e comportamentais extraídas de métodos que passaram por esse tipo de refatoração.

O modelo RF atua como um classificador binário que recebe como entrada o arquivo CSV contendo métricas estruturais e comportamentais do método analisado. Um limiar de probabilidade de 0.5 é utilizado para determinar se o método é candidato à refatoração: métodos classificados positivamente seguem para as próximas etapas da abordagem, enquanto os demais encerram o processo. Além da classificação, o mesmo modelo é reutilizado na Etapa **C**, em conjunto com técnicas de explicabilidade, para justificar as previsões realizadas. A identificação do método candidato também contribui diretamente para o elemento *Where* do critério *W3B*, utilizado na geração de recomendações completas de refatoração.

5.2 Fase II

Esta fase realiza uma análise mais detalhada dos métodos identificados como candidatos à refatoração na Fase I. Essa etapa tem como objetivo gerar recomendações completas, selecionando o fragmento mais adequado para extração e fornecendo explicações sobre a decisão do modelo.

Etapa C: Explicar a Decisão do Modelo.

Nesta etapa, o foco está na interpretabilidade da recomendação. Após a previsão realizada pelo modelo Random Forest, as métricas do método analisado são enviadas para o componente *Consensual Explainer*, responsável por gerar explicações sobre os fatores que influenciaram a decisão do modelo.

O componente utiliza uma estratégia baseada em consenso entre dois técnicas de explicabilidade amplamente utilizadas: SHAP e LIME, o componente é customizável e pode incluir outros modelos de explicabilidade. Como essas técnicas podem gerar interpretações

diferentes para a mesma previsão, o componente combina os resultados para identificar padrões de concordância e produzir explicações mais estáveis e confiáveis.

Como saída, o sistema gera uma lista ranqueada com as cinco características mais relevantes para a decisão do modelo. Essa etapa atende diretamente ao elemento *Why* do critério *W3B*, fornecendo justificativas para a recomendação e aumentando a transparência e a confiança do usuário.

Etapa D: Seleção do Fragmento para Refatoração.

Nesta etapa, os fragmentos candidatos extraídos na Etapa **A** são avaliados por um modelo CodeBERT ajustado (*fine-tuned*). Esse modelo atribui um score de afinidade a cada fragmento, indicando quão adequado ele é para ser extraído com base nas relações semânticas entre o fragmento e o contexto do método original.

O modelo foi treinado utilizando um conjunto de dados especializado composto por pares método-fragmento extraídos de refatorações reais obtidas inicialmente do dataset de Aniche [6] e identificadas com o RefactoringMiner [36]. Diferentemente de abordagens baseadas apenas em métricas, o conjunto de dados considera relações semânticas do código-fonte, permitindo identificar fragmentos mais representativos para extração.

Como resultado, a etapa seleciona o fragmento considerado mais adequado para extração. Esse fragmento, combinado ao método compõe o elemento *Where* do critério *W3B*.

Etapa E: Gerar Recomendação de Refatoração.

Na etapa final, o objetivo é sintetizar todos os artefatos gerados anteriormente em uma recomendação de refatoração completa e estruturada. Para isso, um prompt cuidadosamente elaborado é enviado ao *GPT-4* por meio da API da OpenAI. O prompt incorpora os artefatos gerados ao longo do pipeline, incluindo o fragmento selecionado e sua pontuação de afinidade associada (Etapa **D**), bem como as 5 características (features) mais bem classificadas pelo *Consensual Explainer* (Etapa **C**).

Para a formulação do prompt, adotou-se uma estratégia de *Zero-Shot prompting*, na qual a tarefa é especificada diretamente, sem o fornecimento de exemplos prévios [1]. Como resultado, esta etapa consolida todos os elementos do pipeline em uma saída final que atende os elementos *Which*, *Where* e *Why* do critério *W3B*, produzindo uma recomendação de refatoração explicável e acionável.

5.3 Arquitetura

Figura 6 mostra a arquitetura estruturada em 3 camadas, como detalhada a continuação.

(I) Camada de Interface do Usuário. Esta camada é responsável pela interação entre o desenvolvedor e a ferramenta de recomendação de refatoração dentro da IDE IntelliJ. Essa camada permite a seleção do método a ser analisado e a visualização das recomendações geradas pela abordagem. O componente *Method Selection Manager* captura o método selecionado pelo usuário no projeto local e encaminha a solicitação para o motor de recomendação. Após o processamento, o componente *Recommendation Viewer* apresenta as recomendações de refatoração e as explicações produzidas pela ferramenta diretamente na interface da IDE.

(II) Motor de Recomendação. Esta camada concentra a lógica principal da abordagem e é responsável pela análise dos métodos

selecionados, identificação de candidatos à refatoração e geração de explicações consensuais. Inicialmente, o componente *Fragment Metric Extractor (FME)* extrai métricas estruturais e comportamentais do método, além de identificar fragmentos candidatos à extração. Na sequência, o *Random Forest Classifier* verifica se o método é elegível para refatoração, enquanto o *Fine-tuned CodeBERT Model* realiza a análise semântica dos fragmentos candidatos. Por fim, o componente *Consensus Explainer* gera uma explicação consensual que subsidia a recomendação final apresentada ao usuário.

(III) Serviço de Explicação baseado em LLM. A camada *LLM-based Explanation Service* é responsável por enriquecer as explicações geradas pela abordagem utilizando modelos de linguagem de grande porte (LLMs). O componente *GPT Explanation Generator* recebe as informações produzidas pelos outros componentes e gera explicações em linguagem natural sobre a recomendação de refatoração, auxiliando o desenvolvedor na compreensão da recomendação fornecida pela ferramenta.




Figure 6: Xtract - Arquitetura

6 Trabalhos Relacionados

Diversas abordagens propõem ferramentas e plug-ins para recomendação automática de refatorações, principalmente voltadas para *Extract Method* e *Move Method*.

O **AntiCopyPaster** [4] é um plug-in para IntelliJ IDEA que recomenda a refatoração *Extract Method* para evitar duplicação de código. A abordagem detecta fragmentos duplicados, extrai métricas do código e utiliza uma rede neural convolucional (CNN) para decidir se a refatoração deve ser aplicada. Como saída, a ferramenta apresenta notificações diretamente na IDE. Entre as limitações estão possíveis sobreposições entre exemplos positivos e negativos, o que pode afetar a qualidade do modelo de aprendizado de máquina.

O **DOIMR** [32] é uma abordagem interativa que permite aos desenvolvedores explorar métricas de qualidade e localização do código para gerar recomendações de refatoração personalizadas. A abordagem combina busca multiobjetivo, agrupamento de soluções e feedback iterativo do usuário para melhorar atributos de qualidade.

Como limitação, a ferramenta exige usuários experientes, e pode tornar o processo cansativo devido à interação contínua.

O **RMove** [9] é uma ferramenta para recomendação da refatoração *Move Method* para a remoção do *code smell Feature Envy*. A abordagem utiliza grafos de dependência de métodos e árvores sintáticas abstratas (AST) para representar características estruturais e semânticas do código, treinando classificadores para sugerir o *Move Method*. Sua principal limitação está na dependência de bases de dados de projetos open source, que podem conter ruídos.

7 Conclusão

Este artigo apresentou a **Xtract**, um plug-in integrado à IDE IntelliJ desenvolvido para auxiliar desenvolvedores na identificação de oportunidades de refatoração do tipo *Extract Method*, por meio de recomendações explicáveis. Diferentemente das abordagens existentes, que frequentemente fornecem recomendações parciais, a ferramenta proposta é orientada pelo critério W3B (*Which*, *Where*, *Why* e *Benefits*) para gerar recomendações mais abrangentes e compreensíveis diretamente no ambiente de desenvolvimento. Entretanto, devido às limitações de espaço do artigo, esta versão priorizou os elementos do critério W3B relacionados à identificação do trecho candidato (*Which*), sua localização (*Where*) e à explicação da recomendação (*Why*).

A abordagem combina métricas estruturais, análise semântica e técnicas de Inteligência Artificial Explicável para melhorar tanto a qualidade das recomendações quanto a confiança do desenvolvedor nas decisões produzidas pela ferramenta. A arquitetura proposta integra o componente *Fragment Metric Extractor (FME)*, um classificador *Random Forest*, um modelo *Fine-tuned CodeBERT* e o módulo *Consensus Explainer* para gerar recomendações fundamentadas em práticas reais de refatoração. Além disso, a integração de um LLM possibilita a geração de explicações contextualizadas em linguagem natural, apresentadas diretamente na IDE.

Sob a perspectiva do usuário, a ferramenta foi projetada para minimizar interrupções no fluxo de desenvolvimento, integrando o processo de recomendação diretamente à interface da IDE IntelliJ. Dessa forma, o desenvolvedor pode analisar métodos diretamente no editor de código-fonte e receber recomendações em tempo real por meio de uma janela lateral dedicada.

De forma geral, este trabalho contribui para reduzir a distância entre técnicas automatizadas de recomendação de refatoração e sua adoção prática em ambientes reais de desenvolvimento de software.

Disponibilidade de Artefatos

O código-fonte do **Xtract** está licenciado sob a licença MIT e disponível no GitHub em <https://github.com/Advanse-Lab/xtract-plugin-intellij>.

Agradecimentos

Este estudo foi financiado em parte pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código Financeiro 001. Este trabalho recebeu apoio da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), por meio do processo nº 2026/06067-0, vinculado ao processo nº 2025/07160-0.

Referências

- [1] Josh Achiam, Steven Adler, Sandhini Agarwal, Lama Ahmad, Ilge Akkaya, Florencia Leoni Aleman, Diogo Almeida, Janko Altenschmidt, Sam Altman, Shyamal Anadkat, et al. 2023. Gpt-4 technical report. *arXiv preprint arXiv:2303.08774* (2023).
- [2] Vahid Alizadeh, Houcem Fehri, and Marouane Kessentini. 2019. Less is More: From Multi-objective to Mono-objective Refactoring via Developer’s Knowledge Extraction. In *2019 19th International Working Conference on Source Code Analysis and Manipulation (SCAM)*. IEEE, 181–192.
- [3] Vahid Alizadeh, Mohamed Amine Ouali, Marouane Kessentini, and Meriem Chater. 2019. RefBot: Intelligent software refactoring bot. In *2019 34th IEEE/ACM International Conference on Automated Software Engineering (ASE)*. IEEE, 823–834.
- [4] Eman Abdullah AlOmar, Anton Ivanov, Zarina Kurbatova, Yaroslav Golubev, Mohamed Wiem Mkaouer, Ali Ouni, Timofey Bryksin, Le Nguyen, Amit Kini, and Aditya Thakur. 2023. Just-in-time code duplicates extraction. *Information and Software Technology* 158 (2023).
- [5] Plamen P Angelov, Eduardo A Soares, Richard Jiang, Nicholas I Arnold, and Peter M Atkinson. 2021. Explainable artificial intelligence: an analytical review. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery* 11, 5 (2021), e1424.
- [6] Mauricio Aniche, Erick Maziero, Rafael Durelli, and Vinicius HS Durelli. 2020. The effectiveness of supervised machine learning algorithms in predicting software refactoring. *IEEE Transactions on Software Engineering* 48, 4 (2020), 1432–1450.
- [7] Guisella Armijo, Daniel Santibañez, Rafael Durelli, and Valter Camargo. 2024. On the Employment of Machine Learning for Recommending Refactorings: A Systematic Literature Review. In *Anais do XXXVIII Simpósio Brasileiro de Engenharia de Software (Curitiba/PR)*. SBC, Porto Alegre, RS, Brasil, 334–345. doi:10.5753/sbes.2024.3436
- [8] Di Cui, Qiangqiang Wang, Siqi Wang, Jianlei Chi, Jianan Li, Lu Wang, and Qingshan Li. 2023. REMS: Recommending Extract Method Refactoring Opportunities via Multi-view Representation of Code Property Graph. In *2023 IEEE/ACM 31st International Conference on Program Comprehension (ICPC)*. IEEE.
- [9] Di Cui, Siqi Wang, Yong Luo, Xingyu Li, Jie Dai, Lu Wang, and Qingshan Li. 2022. RMove: Recommending Move Method Refactoring Opportunities using Structural and Semantic Representations of Code. In *2022 IEEE International Conference on Software Maintenance and Evolution (ICSME)*. IEEE, 281–292.
- [10] Warteruzannan Soyer Cunha, Guisella Angulo Armijo, and Valter Vieira de Camargo. 2020. InSet: A Tool to Identify Architecture Smells Using Machine Learning. In *Proceedings of the XXXIV Brazilian Symposium on Software Engineering (Natal, Brazil) (SBES ’20)*. Association for Computing Machinery, New York, NY, USA, 760–765. doi:10.1145/3422392.3422507
- [11] Arun Das and Paul Rad. 2020. Opportunities and challenges in explainable artificial intelligence (xai): A survey. *arXiv preprint arXiv:2006.11371* (2020).
- [12] Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. 2019. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. In *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics (NAACL)*. 4171–4186.
- [13] Zhangyin Feng, Daya Guo, Duyu Tang, Nan Duan, Xiaocheng Feng, Ming Gong, Linjun Shou, Bing Qin, Ting Liu, Daxin Jiang, et al. 2020. Codebert: A pre-trained model for programming and natural languages. *arXiv preprint arXiv:2002.08155* (2020).
- [14] Marios Fokaefs, Nikolaos Tsantalis, and Alexander Chatzigeorgiou. 2007. Jdeodorant: Identification and removal of feature envy bad smells. In *2007 IEEE international conference on software maintenance*. IEEE, 519–520.
- [15] Martin Fowler, Kent Beck, John Brant, William Opdyke, and Don Roberts. 1999. *Refactoring: Improving the Design of Existing Code*. Addison-Wesley Professional, Boston, MA, USA.
- [16] Prashant Gohel, Priyanka Singh, and Manoranjan Mohanty. 2021. Explainable AI: current status and future directions. *arXiv preprint arXiv:2107.07045* (2021).
- [17] David Gunning. 2017. Explainable artificial intelligence (xai). *Defense advanced research projects agency (DARPA), nd Web* 2, 2 (2017), 1.
- [18] David Gunning, Mark Stefik, Jaesik Choi, Timothy Miller, Simone Stumpf, and Guang-Zhong Yang. 2019. XAI—Explainable artificial intelligence. *Science Robotics* 4, 37 (2019), eaay7120.
- [19] Jalisson Henrique, Marcos Dósea, and Cláudio Sant’Anna. 2021. Minerando Motivações para Aplicação de Extract Method: Um Estudo Preliminar. In *Anais do IX Workshop de Visualização, Evolução e Manutenção de Software*. SBC, 21–25.
- [20] Ayaka Imazato, Yoshiki Higo, Keisuke Hotta, and Shinji Kusumoto. 2017. Finding extract method refactoring opportunities by analyzing development history. In *2017 IEEE 41st Annual Computer Software and Applications Conference (COMPSAC)*, Vol. 1. IEEE, 190–195.
- [21] Sotiris B Kotsiantis, I Zaharakis, and P Pintelas. 2007. Supervised machine learning: A review of classification techniques. *Emerging artificial intelligence applications in computer engineering* 160 (2007), 3–24.
- [22] Zarina Kurbatova, Ivan Veselov, Yaroslav Golubev, and Timofey Bryksin. 2020. Recommendation of Move Method Refactoring Using Path-Based Representation of Code. In *Proceedings of the IEEE/ACM 42nd International Conference on Software Engineering Workshops*. 315–322.
- [23] Meir M Lehman. 1980. Programs, life cycles, and laws of software evolution. *Proc. IEEE* 68, 9 (1980), 1060–1076.
- [24] Hui Liu, Zhifeng Xu, and Yanzhen Zou. 2018. Deep learning based feature envy detection. In *Proceedings of the 33rd ACM/IEEE International Conference on Automated Software Engineering*. 385–396.
- [25] Tom Mens and Tom Tourwé. 2004. A survey of software refactoring. *IEEE Transactions on software engineering* 30, 2 (2004), 126–139.
- [26] R. Michalski, J. Carbonell, and T. Mitchell. 1985. *Machine Learning: Artificial Intelligence Approach*.
- [27] Kevin P. Murphy. 2023. *Probabilistic Machine Learning: Advanced Topics*. The MIT Press, Cambridge, MA. 1360 pages.
- [28] Ally S Nyamawe, Hui Liu, Nan Niu, Qasim Umer, and Zhendong Niu. 2020. Feature requests-based recommendation of software refactorings. *Empirical Software Engineering* 25, 5 (2020), 4315–4347.
- [29] William F Opdyke. 1992. Refactoring object-oriented frameworks. (1992).
- [30] Indranil Palit, Gautam Shetty, Hera Arif, and Tushar Sharma. 2023. Automatic refactoring candidate identification leveraging effective code representation. In *2023 IEEE International Conference on Software Maintenance and Evolution (ICSME)*. IEEE, 369–374.
- [31] P Jonathon Phillips, Carina A Hahn, Peter C Fontana, David A Broniatowski, and Mark A Przybicki. 2020. Four principles of explainable artificial intelligence. *Gaithersburg, Maryland* (2020).
- [32] Soumaya Rebai, Vahid Alizadeh, Marouane Kessentini, Houcem Fehri, and Rick Kazman. 2020. Enabling decision and objective space exploration for interactive multi-objective refactoring. *IEEE Transactions on Software Engineering* (2020).
- [33] Cleiton Silva, Amanda Santana, Eduardo Figueiredo, and Mariza AS Bigonha. [n. d.]. Revisiting the Bad Smell and Refactoring Relationship: A Systematic Literature Review. ([n. d.]).
- [34] Haykin Symon. 1999. *Neural networks: a comprehensive foundation*. Prentice-Hall (1999).
- [35] Ricardo Terra, Marco Tulio Valente, Sergio Miranda, and Vitor Sales. 2018. JMove: A novel heuristic and tool to detect move method refactoring opportunities. *Journal of Systems and Software* 138 (2018), 19–36.
- [36] Nikolaos Tsantalis, Ameya Ketkar, and Danny Dig. 2022. RefactoringMiner 2.0. *IEEE Transactions on Software Engineering* 48, 3 (2022), 930–950. doi:10.1109/TSE.2020.3007722
- [37] David van der Leij, Jasper Binda, Robbert van Dalen, Pieter Vallen, Yaping Luo, and Mauricio Aniche. 2021. Data-driven extract method recommendations: a study at ING. In *Proceedings of the 29th ACM Joint Meeting on European Software Engineering Conference and Symposium on the Foundations of Software Engineering*. 1337–1347.
- [38] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N Gomez, Łukasz Kaiser, and Illia Polosukhin. 2017. Attention is All You Need. In *Advances in Neural Information Processing Systems (NeurIPS)*.
- [39] Sihan Xu, Chenkai Guo, Lei Liu, and Jing Xu. 2017. A log-linear probabilistic model for prioritizing extract method refactorings. In *2017 3rd IEEE International Conference on Computer and Communications (ICCC)*. IEEE, 2503–2507.
- [40] Ruru Yue, Zhe Gao, Na Meng, Yingfei Xiong, Xiaoyin Wang, and J David Morgenthaler. 2018. Automatic clone recommendation for refactoring based on the present and the past. In *2018 IEEE International Conference on Software Maintenance and Evolution (ICSME)*. IEEE, 115–126.