

DISCUSSIONE DI LAUREA

HybridRepair

Riparazione automatica di NullPointerException, senza Perfect Fault
Localization

CANDIDATO

Mario Ponticiello

RELATORE

Porfirio Tramontana

SEDE

Università Federico II di Napoli · A.A. 2025-2026

Manutenzione e Automated Program Repair

\$2,08T

Costo del software di bassa qualità negli USA nel solo 2020, secondo il Consortium for Information & Software Quality. Affidare il debugging al solo intervento umano è sempre meno sostenibile.

L'**APR** non aspetta lo sviluppatore: un sistema automatico affronta il difetto in tre passi.

01

Analizza

il codice sorgente



02

Localizza

il difetto



03

Genera

la patch

Le NullPointerException

pur essendo semplici, sono tra i **più diffusi**.


37,2%

dei fallimenti in sistemi come
Mozilla e Apache


70%

dei crash nelle applicazioni Java
in produzione

sono bug del **flusso dei valori**. Il difetto nasce lontano dal crash.

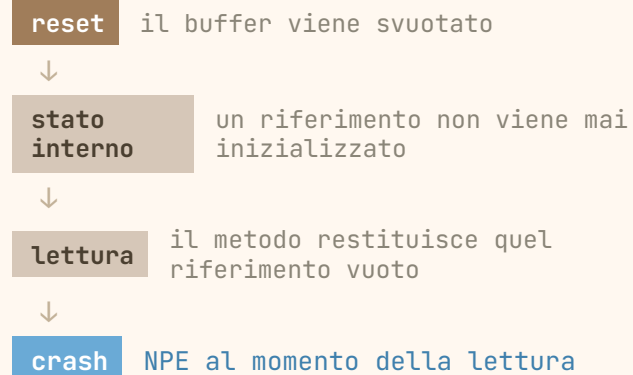


Dal sintomo alla causa



Il bug JacksonCore-8

1 • DIAGNOSTICARE — LA CATENA CAUSALE



2 • GUIDARE — LA SPECIFICA SEMANTICA

Dalla catena causale si ricava **cosa il metodo deve fare** : restituire sempre un contenuto valido, anche vuoto, quando non c'è nulla da restituire ma mai un riferimento non inizializzato.

3 • SINTETIZZARE — LA CORREZIONE

La patch generata rispetta quella specifica: nello scenario testato il valore restituito è sempre valido. Tutti i **test passano**.

La PFL non è una soluzione



Prima di riparare un bug bisogna sapere **dove si trova**. La maggior parte dei sistemi LLM aggira il problema anziché risolverlo: riceve la posizione del difetto **già come input**.

✗ PERFECT FAULT LOCALIZATION

Una scorciatoia, non una diagnosi

La posizione del difetto è data **già nota in ingresso**. Irrealistica: se uno sviluppatore sapesse già dov'è il bug, lo avrebbe già corretto.

✓ LOGICFL

Localizzazione, non un'assunzione

Ricostruisce la posizione del difetto **in autonomia**, con un ragionamento causale deterministico: nessuna posizione data in ingresso.

171→64

bug risolti da GIANTREPAIR, con e senza PFL: tolta la scorciatoia, la rete di sicurezza sparisce.

Separare diagnosi e sintesi

DIAGNOSI

Individuare il punto esatto del problema

Richiede un rigore **logico e deterministico** che solo la programmazione logica può garantire.

SINTESI

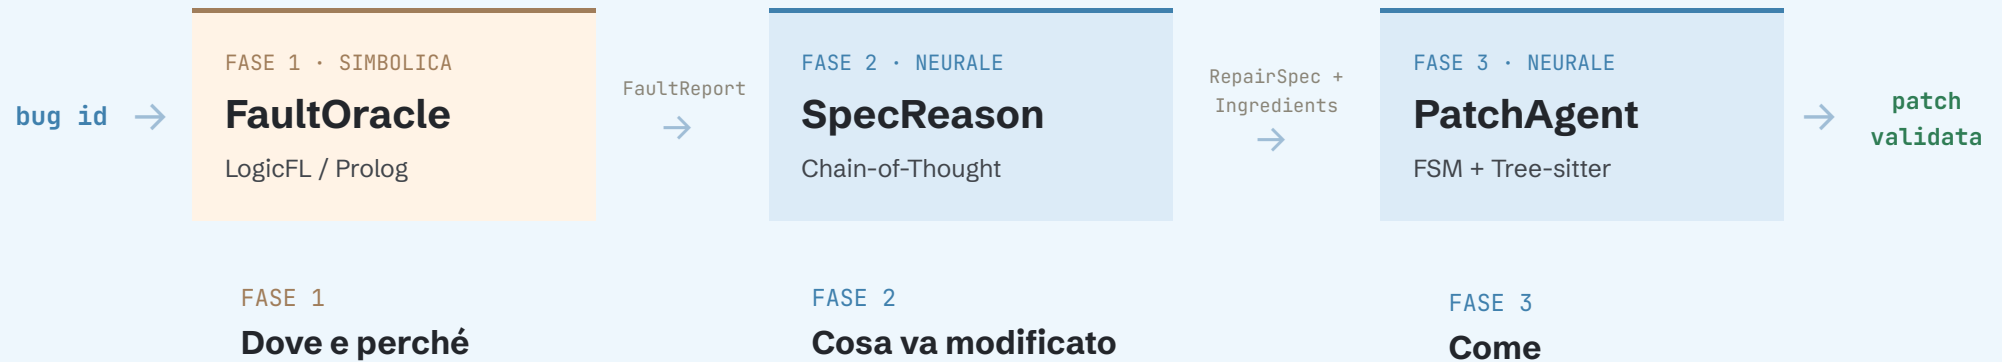
Scrivere codice Java pulito che passa i test

Dominio in cui gli **LLM eccellono**.

Il contributo non è sviluppare i singoli strumenti, ma **progettare l'architettura** che trasforma il referto formale della diagnosi in una guida per la generazione del modello.



Tre fasi disaccoppiate

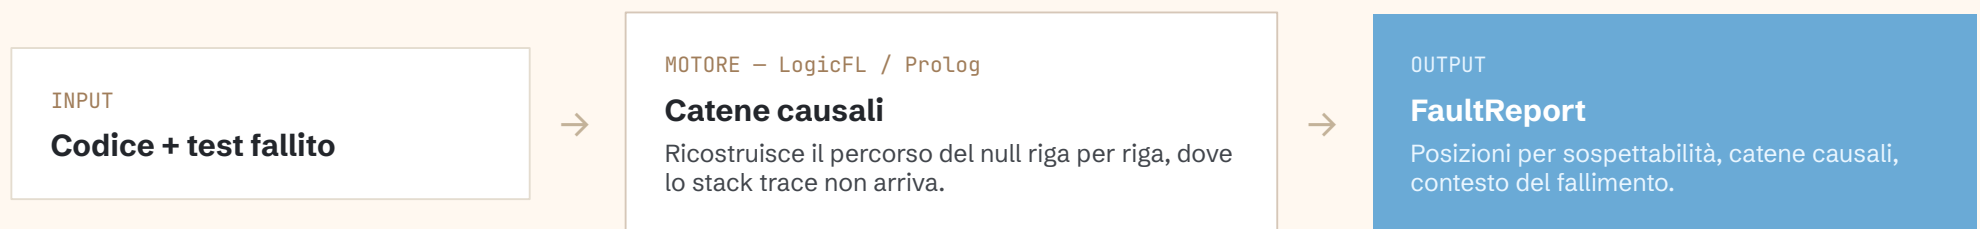


FaultOracle

Localizza il difetto e ne fornisce una **diagnosi causale**, solo tramite analisi statica e ragionamento deduttivo in Prolog.


LogicFL

Fault localization in **Prolog**. Costruisce catene causali formali della propagazione del null dando all'LLM un contesto mirato.



SpecReason

Spec per una specifica rigorosa, **Reason** per il ragionamento passo-passo. Trasforma la diagnosi in conoscenza per il modello.



PatchAgent

Traduce la RepairSpec in una modifica concreta del codice, come una **macchina a stati** che attraversa quattro fasi.



Obiettivi e domande di ricerca

Misurare in modo rigoroso la capacità del sistema di generare patch **plausibili** e **valide** su bug NPE reali, e confrontare le prestazioni con lo stato dell'arte.

RQ1 Quante patch **plausibili** è in grado di generare HybridRepair sui bug NPE del dataset?

RQ2 Quante delle patch plausibili generate sono anche **valide**, semanticamente equivalenti al Ground Truth?

RQ3 Come si **confrontano** le prestazioni con VibeRepair sullo stesso dataset?

Dataset e competitor

37 bug NPE

estratti da **Defects4J v2**, distribuiti su **12 progetti** Java open source eterogenei.

IL COMPETITOR

VibeRepair

Sistema APR basato solo su LLM, **specification-centric** : traduce il codice in una specifica, la corregge, e genera la patch da quella.

Non localizza il difetto in autonomia: assume la **Perfect Fault Localization** , il punto esatto del bug come dato noto a priori.

Metriche

PATCH PLAUSIBILE

Compila ed **supera l'intera suite di test** , senza garanzia di correttezza semantica fuori dai casi coperti dai test.

PATCH VALIDA

Una patch plausibile che, dopo revisione manuale, risulta **equivalente al Ground Truth**: risolve la causa, non solo il sintomo.

HR Plaus.

Bug con almeno una patch plausibile, sul totale del dataset.

HR Valida

Precisione: patch plausibili giudicate valide, sul totale delle plausibili.

Plausibile AND Valida

Patch valide sul totale del dataset: base omogenea di confronto con VibeRepair.

Risultati e confronto con VibeRepair

22/37

Patch plausibili

59,5% — superano la suite di test

15/22

Patch valide

precisione 68,2% — revisione manuale

40,5%

Validità assoluta


15 valide sull'intero dataset

CONFRONTO CON LO STATO DELL'ARTE

15 vs 14

patch valide, stesso dataset
di 37 bug

HybridRepair supera lo stato dell'arte **senza Perfect Fault Localization**, mentre VibeRepair ne dipende strutturalmente.



21 bug su 37 risolti da almeno uno dei due sistemi; +16 da nessuno.

I due approcci sono **complementari**: HybridRepair eccelle sui bug multi-punto, dove la catena causale guida verso tutti i punti da correggere.

Threats to Validity

VALIDITÀ INTERNA

Soggettività nella validazione manuale delle patch, mitigata con un criterio conservativo.

Non-determinismo del LLM: i risultati vengono da un'unica esecuzione della pipeline.

VALIDITÀ ESTERNA

Dataset limitato a 37 bug NPE: i pattern osservati potrebbero non trasferirsi ad altre categorie di difetti.

VALIDITÀ DI COSTRUTTO

Il Ground Truth è la soluzione degli sviluppatori originali: alternative ugualmente valide rischiano di essere scartate, un bias che sottostima le prestazioni.

Unire i due mondi: senza PFL, con fault localization euristica

01

La causa radice, non la correzione superficiale

HybridRepair fa precedere la generazione della patch da una **localizzazione causale autonoma**, LogicFL, e da una **guida semantica**, SpecReason.

02

Competitivo, senza la rete di sicurezza della PFL

HybridRepair supera VibeRepair sullo stesso dataset. Il contributo non sta nel margine numerico, ma nel fatto di localizzare il difetto **in autonomia, con una fault localization euristica**, invece di assumerlo noto a priori come VibeRepair.

Limiti e direzioni: rafforzare l'oracolo di test, una validazione critica indipendente dal modello generatore, ed estendere il dataset ad altre categorie di difetti.

Grazie per l'attenzione

Resto a disposizione per le vostre domande.

CANDIDATO

Mario Ponticiello

HYBRIDREPAIR

Riparazione di NPE