Szegedi Tudományegyetem

Informatikai Intézet

Szoftverfejlesztés Tanszék

Biztonsági sérülékenységek javításának empirikus vizsgálata és az ehhez szükséges eszközök fejlesztése

Készítette:

Mosolygó Balázs József

Témavezető:

Antal Gábor, tudományos segédmunkatárs

SZTE TTIK Szoftverfejlesztés Tanszék

Szeged

2021

Tartalomjegyzék

Feladatkiírás

A szakdolgozat célja, hogy a hallgató több, létező nyílt forrású rendszert továbbfejlesszen (amely során megfelelően kezelje a GitHub API korlátait). A fejlesztések közben készítsen egységteszteket az alkalmazásokhoz. Az elkészült alkalmazásokat a hallgatónak több száz rendszeren kell futtatnia, az esetlegesen felmerülő hibákat javítania, majd pedig a kapott eredményeket fel kell dolgoznia. Az eredmények feldolgozásához elsősorban Python nyelvű szkripteket kell készítenie, az eredmények megjelenítésére lehetőség szerint a Python `matplotlib` modulját használja, melynek segítségével a hallgató elmélyülhet a Python adatfeldolgozást támogató könyvtáraiban. A kapott eredmények közötti anomáliák felderítése is a hallgató feladata.

Tartalmi összefoglaló

A téma megnevezése:

CVE bányászatra alkalmas eszközök készítése. A segítségükkel létrehozott adatok elemzése.

Megadott feladat megfogalmazása:

A feladatom az volt, hogy elkészítsek, illetve tovább fejlesszek nyílt forráskódú eszközöket, amelyek képesek együtt, és önállóan működni, majd ezeket felhasználva több száz projekt sérülékenységi adatát megvizsgáljam. A vizsgált adatokból ábrákat készítettem, amik a dolgozatban láthatóak.

A megoldási mód:

GitHubon elérhető projektek módosításai vizsgálom végig, CVE említéseket keresve. A vizsgálat során létrejött adatokból statisztika készült, ezekhez ábrákat készítettem.

Alkalmazott eszközök, módszerek:

Python nyelv, PyTest, PyPi, Travis CI, VSCode, MatPlotLib, Seaborn, Pandas, AirTable, Numpy

Elért eredmények:

Sikerült elkészíteni 2 eszközt, melyek feladatukat helyesen végzik, segítségükkel egy több nyelven, és több száz projekten átívelő adatbázis jött létre. Az adathalmazt vizsgálva több érdekes tulajdonságát sikerült megállapítani a különböző sérülékenységeknek.

Kulcsszavak:

CVE, CWE, vulnerablity, Python, data mining, GitHub

1. fejezet

Bevezetés

A szoftverfejlesztés egy rohamosan terjeszkedő iparág, a fejlődése és belső működése gyökeresen különbözik a legtöbb társától, hiszen a létrehozott termék szellemi értéket képvisel elsősorban, így nehéz objektív módon értékelni, összehasonlítani fejlesztési folyamatok, technikák hatékonyságát. Minden fejlesztőcsapat törekszik a lehető legnagyobb minőség, és biztonság elérésére, ennek ellenére azonban, gyakran előfordul, hogy kisebb-nagyobb hibák keletkeznek. Ezek észlelése és javítása azonban, csak az első lépések a hiba eltüntetésében, ugyanis a felhasználókat, legyenek azok más fejlesztők, vagy végfelhasználók, értésíteni kell arról, hogy szükséges lehet az újabb verzióra frissíteniük. A különböző projektekben alkalmazott rutinok eltérése miatt az ilyen tájkoztatás egy rendkívül komoly kihívás. A célból, hogy az információ megosztása könnyebb legyen a Mitre Vállalat 1999-ben létrehozta a CVE (Common Vulnerabilities and Exposures)[1] koncepciót, aminek lényege egy publikus adatbázis készítése volt, ahol egységes nevezési konvenciók segítségével könnyítették a sérülékenységekkel, és azok javításával kapcsolatos adatok rendszerezését. Egy CVE egy konkrét projekt sérülékenységét írja le, és rendel hozzá egy egyedi azonosítót, míg egy CWE (Common Weakness Enumeration)[2] sérülékenységek egy csoportját jelöli. Habár az adatbázis rengeteg hasznos információt tartalmaz, mint például bizonyos hibák leírása, súlyossága és rövid leírása, nem ad minden kérdésre választ.

A különböző sérülékenységek kezelésében azonban továbbra is jelentős különbségek

[1] `https://cve.mitre.org`
[2] `https://cwe.mitre.org`

vannak, nyelveket vagy akár csak projekteket tekintve. Annak érdekében, hogy ezeket a különbségeket megvizsgálhassuk, létrehoztunk egy adatbázist, ami tartalmazza néhány nagyobb nyílt forráskódú projekt CVE-inek jelentős részét, hogy ennek segítségével alaposabb belátást nyerhessünk különböző nyelvek, illetve projektek hibákhoz, sérülékenységekhez való hozzáállásába, javítási folyamataiba. A rendelkezésre álló adatok segítségével lehetőség nyílik a hibák mélyebb elemzésére, a hozzájuk kapcsolódó statisztikák létrehozására, valamint további adatok kinyerésére, mint például a konkrét javítást végző kódrészletek, amik akár automatikus hiba előrejelző rendszerekben is felhasználhatóak. Érdemes megjegyezni, hogy egy projekt sebezhetősége nem feltétlen csak az adott alkalmazást érintheti, hanem több, azt használó termékre is kiterjedhet. A függőségek sérülékenységeinek kezelése további kérdés, hiszen amíg egy használt eszközben sérülékenységek vannak, addig az azt használóban is megjelennek.

1.1. Dolgozat felépítése

A következő fejezetben ismertetjük, hogy mi motivált minket a projekt elkezdésében, illetve milyen támpontokat tartottunk szem előtt a projekt készítése során. A 3. fejezetben említést teszünk néhány kapcsolódó munkáról, amiket feldolgoztunk. A 4. fejezetben részletezzük, hogy hogyan készítettük elő a szükséges eszközöket és adatokat. Az 5. fejezetben pedig ismertetjük az ezek alapján előállított statisztikákat, és következtetéseket. Végül pedig a 6. fejezetben összegezzük az elért eredményeket, és jövőbeli terveket.

2. fejezet

Motiváció

Egy CVE bejegyzés tartalmazza, a sérülékenység rövid leírárást, legalább egy nyilvánosan elérhető referenciáját, súlyosságát, CWE besorolását, illetve az azonosítóját. A CVE-k rengeteg hasznos információt tesznek elérhetővé, és CWE-kbe csoportosítva általánosabb információ is elérhető velük kapcsolatban. Egy egyszerű keresés segítségével nem tudunk általános adatokhoz hozzájutni egy projekt vagy akár egy nyelv CVE-kkel kapcsolatos javítási tendeciáihoz, azonban erre komoly szükség lehet, ha jobban meg szeretnék érteni a komoly sérülékenységek kiváltó okait, és kiküszöbölni azokat. A konkrétabb megoldások ismeretében könnyebben javíthatóvá, elkerülhetővé, illetve detektálhatóvá tehetjük a CVE-ket, és általuk a bizonyos típusú sérülékenységeket is.

Az általunk létrehozott adatbázis lehetőséget nyújt arra, hogy megvizsgálhassuk az egyes hibákra biztosított megoldásokat, illetve az ezekkel kapcsolatos statisztikák is rendelkezésre állnak. Ezek segítségével gyorsan és megalapozottan tudunk értékes következtetéseket levonni, nem csak egy bizonyos sérülékenység kiküszöböléséről, hanem akár egy sérülékenységi csoport (CWE) általános nyelvi tulajdonságait is megtekinthetjük.

Megtudhatjuk, hogy az adott nyelv nyílt forráskódú projektjeiben mely hiba csoportok fordulnak elő, milyen gyakorisággal, és mekkora lehet a javítási költségük. Nem csak időt és energiát spórolhat meg a fejlesztőknek és tesztelőknek, hanem a teljes folyamatot költség- és időhatékonyabbá teheti. Továbbá felgyorsíthatja a termékeket függőségként használó projektek reakció idejét, ami csökkenti a visszaélés esélyét. A sérülékenységek javításához való hozzáálláson is változtathat, ha tudjuk, hogy az általunk használt termék fejlesztői gyorsan és hatékonyan javítanak hibákat, ebben az esetben ugyanis nem

feltétlen van szükség saját megoldást keresni, elegendő lehet várni a frissítésre, míg ellenkező esetben akár a legmagasabb prioritást is képezheti egy-egy felfedezett hiba helyi megoldása.

Annak érdekében, hogy ezeket az információkat cégek, és fejlesztők számára elérhetővé tegyük létrehoztunk egy adatbázist, amiben különböző nyelvek CVE javításaival kapcsolatos adatokat tárolunk.

A CVE adatain kívül az adatbázis nyelvekre és projektekre lebontható információt tartalmaz arról, hogy egy-egy hibát mennyi idő, hány kódsor- és fájlváltoztatás kiküszöbölni, illetve a konkrét javítást tartalmazó commit azonosítóját. Egy commit, pedig nem más, mint egy bizonyos változtatás egy kódbázison, amit ennek egyedi hash azonosítójával bármikor megtalálhatunk, és elemezhetünk.

3. fejezet

Kapcsolódó munkák

Amióta léteznek szoftverek, előfordulnak sérülékenységek is. A különböző hibák felismerése, és megelőzése hosszú és változatos múltra tekint vissza, amiben új fejezetet nyitott a Mitre vállalat, amikor 1999-ben bevezették a CVE fogalmát, aminek segítségével a különböző hibák könnyen kategorizálhatóva váltak ezáltal csökkentve a további projektekre való tovább terjedésük valószínűségét.

Habár a CVE-k bevezetése megkönnyítette a biztonsági sérülékenységekkel kapcsolatos kommunikációt a különböző projektek köztött, ez továbbra is hatalmas kihívást jelent. Jukka Ruohonen és társai [15][16] megvizsgálták a a projektek közötti koordináció folyamatát nyílt levelezési listák segítségével, és azt találták, hogy viszonylag gyakran csúszások fordulnak elő, amik hatására a CVE-k később jelennek meg a hivatalos adatbázisokban. Különösen nagy eséllyel fordulnak elő nagyobb csúszások hétvégén. Az ilyen jelentésbeli késések komoly károkat is okozhatnak, Clemens Sauerwein és társai [19] egy alternatív módját vizsgálták meg a hibákról való információ gyűjtésnek. A Twitter szociális média platformon elérhető fejlesztők aktivitását vizsgálva azt találták, hogy a biztonsági sérülékenységek negyedéről volt a hivatalos publikáció előtt szó a oldalon.

Annak ellenére, hogy nagy mennyiségű CVE bejegyzés áll rendelkezésre, ezek közül nem mindegyik biztosít kellő részletességű információt. Ennek a problémának orvosolását tűzték ki célul Sarang Na és társai [13]. A naív Bayes algoritmus felhasználásával állítottak elő CWE csoportosításokat már létező CVE-khez, annak érdekében, hogy a hiányosságokat pótolják. 3 évvel később Ying Dong és csapata készített által egy kutatást [3] aminek célja az volt, hogy felfedezzék mennyi inkonzisztens információ található

az NVD[1] adatbázisa, és a különböző CVE-k leírása között. Több mint 78000 CVE megvizsgálása után arra az eredményre jutottak, hogy nem csak gyakoriak az ily módon hibás adatok, de az is előfordulhat, hogy nem jelölnek meg komoly hibákat, vagy nem hibás verziókat jelölnek meg sérülékenyként. További problémára lett figyelmes Luis Gustavo Araujo Rodriguez és csapata [14], amikor arra próbáltak fényt deríteni, hogy mennyi az átlagos késés egy hiba javítása és az NVD adatbázisába való bekerülése között. Eredményeik szerint 1-7 nap késés is előfordulhat, illetve az is megtörténhet, hogy nem hivatalos oldalakon hamarabb és pontosabban elérhetővé válik a sérülékenységgel kapcsolatos információ.

Fabio Massacci és Viet Hung Nguyen [10] több sérülékenységgel és biztonsággal foglalkozó problémát vizsgált. Összefoglalták a különböző kutatások során használt adatbázisok jellemzőit, és összehasonlították ezeket. Ezen felül különböző kísérleteket végeztek Mozilla Firefox kódbázisában, hogy megmutassák, hogy különböző adatbázisok használata különböző eredményeket hozhat. Ezzel azt is hangsúlyozzák, hogy az adathalmaz megválasztása egy kulcskérdés az ilyen területű kutatásokban.

Annak érdekében, hogy pontosabb információ legyen elérhető gyorsabban, Luis Alberto Benthin Sanguino és Rafael Uetz [18], készítettek egy eszközt aminek segítségével lehetséges könnyedén egy alkalmazáshoz CPE-t, azaz egy egységes nevezéktan szerint megalkotott nevet rendelni, hogy könnyebb legyen automatikus hiba keresést végezni a szoftveren. Eredeti terveik szerint automatikusan szerették volna létrehozni a hozzárendeléseket, azonban számos nehézség merült fel ezzel kapcsolatban, és végül nem találták praktikusnak. Zhengzi Xu és társai [23] szintén a CVE adatok automatikus kiegészítését tűzték ki célul, ők azonban a bináris szinten érzékelik automatikusan a különböző potenciális hibákat.

A CVE-k súlyossági értékét figyelembe véve lehetséges prioritást rendelni különböző hibák javításához, ehhez készített egy algoritmust Anshu Tripathi és Umesh Kumar Singh [21].

Andrew Kronser [6] tézisében arról beszél, hogy bizonyos típusú szoftverek gyakrabban szenvednek biztonsági sérülékenységektől mint mások. Ennek oka nem csak a nagyobb potenciális támadó bázis, hanem a használt eszközök széleskörűsége, ami miatt

[1] `https://nvd.nist.gov/vuln`

lehetséges, hogy megnő a támadási felület. A legsérülékenyebb eszközök változnak attól függően, hogy mi az aktuális leggyakoribb sérülékenység, például 2008 és 2010 között az SQL injekció volt a domináns hiba. A CVE adatbázis növekedésének köszönhetően egyre hatékonyabb adatbányászó eszközök állíthatók elő, melyek segítségével a különböző támadásokat lehetővé tevő hibák könnyebben észlelhetőek lesznek.

A hibák előfordulási trendjeit V. Mounika és társai [11] megvizsgálták, és arra jutottak, hogy a közismert biztonsági sérülékenységek előfordulási aránya idővel változik. Thanapon Bhuddtham és Pirawat Watanapongse [2] a biztonsági sérülékenységek trendjeit kihasználva T-CVE-ket készítettek, amik korai figyelmeztetésekkel látják el a biztonsági szakértőket. Hasonlóan Richard Kuhn és társai [7] is megfigyeltek bizonyos trendeket a sérülékenységekkel kapcsolatban. Ők arról írnak, hogy bár a nagyon súlyos hibák aránya csökkenő tendenciát mutat, az implementációval kapcsolatosaké viszont nő. Ebbe a csoportba tartoznak olyan programozói hibák, mint a bemeneti adatok ellenőrzésének hiánya.

Stefan Frei és társai [4] pedig egy kiterjedt vizsgálat során megállapították azokat az időpontokat, amikor az egyes sérülékenységeket felfedezték, publikálták, kihasználták, illetve kijavították. Ezen kívül létrehoztak egy eszközt, aminek segítségével mérhetővé tehető a kihasználtság és a javítás elérhetősége közötti rés. Ezzel azt is megállapították, hogy 2006 előtt a támadók sokkal gyorsabban reagáltak az egyes sérülékenységekre, mint a gyártók, manapság viszont ez általánosságban fordítva igaz.

Ezt a megállapítást támasztja alá Muhammad Shahzad és társai [20] kutatása. Ők szintén egy nagyméretű adathalmazon dolgoztak, hogy megvizsgálják a különböző sérülékenységeket és kategorizálják őket. Megerősítették, hogy a gyártók egyre gyorsabban reagálnak a sérülékenységekre; ezen belül a zárt forráskódú projektek sokkal jobban teljesítenek ilyen téren, mint a nyílt forráskódúak.

Frei és társaihoz hasonlóan Frank Li és Vern Paxson [8] is nagyméretű adathalmazt vizsgált. Ők, mint a mi kutatásunk is, CVE adatbázist használtak a vizsgálathoz, viszont ők igénybe vettek egyéb külső forrásokat is. Ezeket felhasználva megfigyelték a hibajavítások életciklusát, ezek hatását a kódbázisra, illetve hogy mekkora mértékben tudnak a fejlesztők biztonságos és megbízható javításokat végezni. Azt találták, hogy a sérülékenységek javításai jóval kisebb nyomot hagynak a kódbázison, mint az egyéb, nem

biztonsági hibáké. Ezen felül az összes sérülékenység nagyjából harmada több, mint 3 évvel a végleges kijavításuk előtt már ismert volt. Olyan esetek is előfordultak, hogy a hibajavítás nem oldotta meg teljesen a problémát, helyette akár negatív hatást is kifejtett az adott szoftverre.

3.1. Adatbányászat

Annak érdekében, hogy a különböző sérülékenységekkel kapcsolatos adathalmazt bővítsék többen fordulnak adatbányászathoz. A bányászás több forrás alapján is történhet, például Leon Wu és csapata [22] különböző problémakövető adatbázisból (Bugzilla, Debbugs stb.) gyűjtöttek ki hibajavítási információt, aminek segítségével létrehozták a BugMiner eszközt, ami képes ellenőrizni a hibajelentések redundanciáját. Ők elsősorban a jelentések pontosságára koncentráltak mi azonban inkább a fejlesztési és javítási folyamat elemzésére fektettük a hangsúlyt.

Az erős adatbányászati algoritmusok segítségével kiküszöbölhetők a CVE-k korábban tárgyalt hiányosságai, vagyis az adatok, mint például CWE besorolás néha fellépő hiánya. Su Zhang és társai [25] készítettek egy tanulmányt, aminek célja az volt, hogy megvizsgálják, hogy mekkora a valószínűsége annak, hogy egy szoftver tartalmaz egy még fel nem fedezett sérülékenységet. Az ehhez használt kódelemzés mélyrehatóan vizsgálja a forráskódokat, ami sok potenciális hibát képes megtalálni.

Sagar Samtani és társai hozzánk hasonlóan szövegbányászással közelítettek meg egy internet biztonsági problémát [17]. Ők a Shodan [2] kereső motor segítségével elérhető információt dolgozták fel, annak érdekében, hogy SCADA rendszereket[3], és ezek hibáit azonosítsák. Mi ezzel szemben nyílt forráskódú szoftvereket vizsgáltunk meg, forrásként pedig a GitHub [4] szoftver fejlesztési platformot használtuk.

Daisuke Miyamoto és társai [24] létrehoztak egy eszközt, ami képes emberi nyelven megfogalmazott leírások alapján megállapítani egy-egy hiba súlyosságát. A sérülékenységek ilyen irányú összehasonlítása sokat segíthet abban, hogy a kiberbiztonsági szakértők hatékonyabban legyenek képesek reagálni rájuk. Viszont nem kellően pontos ahhoz, hogy

[2] `https://www.shodan.io/`
[3] Felügyeleti Irányítást és Adatgyűjtést végző rendszer
[4] `https://github.com/`

teljesen elhanyagolható legyen az emberi felülvizsgálat.

Az adatbányászat által szerzett információ pontosítása értekében, Xiang Li és csapata [9] készítettek egy algoritmust, ami állításuk szerint jelentősen hatékonyabb mint a korábbiak. Syed Shariyar Murtaza és társai [12] szintén hatékonyabbá akarták tenni a sérülékenységek észlelését, ennek érdekében különböző mintázatokat kerestek a korábbi hiba előfordulásokban. Eredményeik szerint egy adott sérülékenység akár 150-szer is előfordulhat egy szoftverben. Az előforduló sérülékenység típusa pedig, előrejelezhető trendeket követ. Például egyre kevesebb az SQL injekcióval kapcsolatos sérülékenység, azonban egyre több a titkosítási hiba. A hibák további vizsgálatához szükséges lehet egy a mienkhez hasonló adatbázis, hiszen a különböző javítások, és javított hibák adatainak hosszú távú tárolása kulcsfontosságú lehet a további hiba trendek felfedezésében.

4. fejezet

Megközelítés és Implementáció

Az adatbázisunk létrehozásához nyílt forráskódú projekteket elemeztünk. A projekteket a GHTorrent[1] adatbázisa segítségével gyűjtöttük össze. A GHTorrent célja [5], hogy a GitHub Rest API-on keresztül elérhető adatokat, azaz az összes a felhasználók által alapvetően megtekinthető adatot, egy skálázható, offline adatbázisba gyűjtsék. Az adatbázis 2020 januárjában 18 TB adatot tárolt, mi ehhez a Google által készített BigQuery[2] eszköz segítségével fértünk hozzá.

A CVE információk kinyeréséhez létrehoztunk egy programot, ami átvizsgálja a projektek GitHub oldalán levő commitokat, és megnézi, hogy említenek-e egy adott CVE-t, majd ezeket az említő commitokat és a hozzájuk tartozó adatokat elmenti az adatbázisunkba. A módszerünk legfőbb előnye, hogy nincs szükség mélyreható kódelemzésre.

A módszer részletes leírásához bemutatjuk az általunk létrehozott programot. A modulok működésének bemutatása után az általam végzett fejlesztést írom le.

Maga a program három részből áll: a CVE Manager[3] nevű modulból, a Git Log Parser[4] nevű modulból, és a statisztikák feldolgozásáért felelő fő eszközből, a CVE Minerből[5]. Az elkülönítésük azért történt, mert a modulok önmagukban is használhatóak, nem közvetlen részei a fő eszköznek.

[1] `https://ghtorrent.org/`
[2] `https://cloud.google.com/bigquery/`
[3] `https://github.com/gaborantal/cve_manager`
[4] `https://github.com/gaborantal/git-log-parser`
[5] `https://github.com/gaborantal/cve-miner`

4.1. CVE Manager

4.1.1. Működés

A CVE Manager feladata az, hogy a Mitre Vállalat oldaláról letöltse az összes CVE adatait és ezeket kezelje. A letöltés után az adatokat feldolgozza, csoportosítja, és egy helyi PostgreSQL[6] adatbázisban tárolja. A kezeléshez hozzátartozik az adatok lekérdezése is. Ezt többféle tulajdonság alapján is meg lehet tenni, például CVE-knél azonosító, súlyosság, publikáció éve alapján, CWE-k esetében pedig azonosító vagy hozzá tartozó CVE alapján. A legfőbb feladata, a megfelelő előkészületek elvégzése, a CVE Miner helyes futásának érdekében.

4.2. Git Log Parser

4.2.1. Működés

A Git Log Parser[7] feladata a projektek commitjainak a feldolgozása. Ehhez egy Python modult használ, amivel szimulálni tudja a felhasználói parancsokat, ezzel részlegesen megkerülve a GitHub API[8] limitációit. Először is egy elérési útvonalat vár, amely lehet egyetlen projekt helyi címe, vagy egy könyvtár ami több projektet is tartalmaz. Minden esetben szükséges, hogy a projektek `git clone` segítségével legyenek letöltve, hogy a később kiadott parancsok működőképesek legyenek. A commit adatgyűjtési folyamat megkezdésekor a megadott, vagy a könyvtárban elsőként szereplő projekt mappájába navigál, majd a `git log` parancs eredményeit feldolgozva kinyeri a projekt összes commitját és azok meta-adatait. Ezeket egy listába rendezi, majd kiegészíti a megváltozott kódsorok és fájlok számával. A módosítási adatok kinyeréséhez szükséges kapcsolatba lépni a GitHub API-val ami jelentősen limitálja az eszközt. Végül az összes adatot beleírja egy ideiglenes JSON fájlba, amit a fő program kezel.

[6] `https://www.postgresql.org/about/`
[7] `https://github.com/gaborantal/git-log-parser`
[8] `https://developer.github.com/v3/`

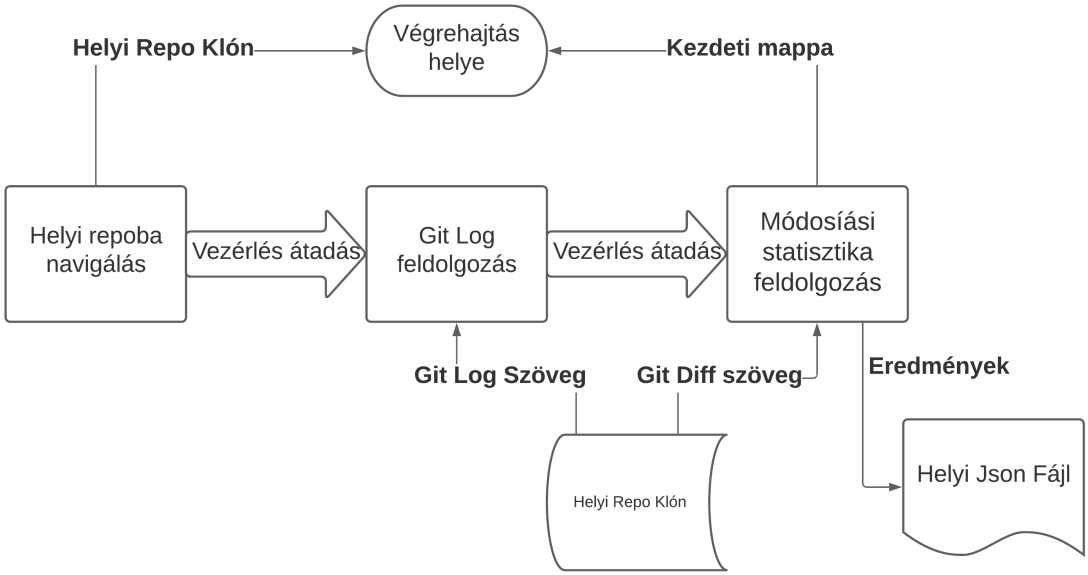

4.1. ábra. A Git Log Parser működése

4.2.2. Fejlesztési folyamat

A Git Log Parser eszköz elkészítésével kezdődött a fejlesztés, hiszen az ez által előkészített adatok a CVE Miner bementetei. Az eszköz már létezett, amikor a fejlesztést megkezdtem, és az elemi feladatának elvégzésére már alkalmas volt, tehát egy `git log` szöveget képes volt egy osztályként eltárolni, azonban ez még nem volt elégséges a teljes feladatkörének betöltésére. Nem volt képes sem a `git log` önálló lekérdezésére, ezt csak paraméterként tudta csak fogadni, illetve az eredményeit egyszerűen a konzolra írta ki, nem mentette futás után perzisztens módon.

Első lépésként biztosítottam a lehetőséget, hogy parancssori argumentumként ki lehessen választani, hogy melyik helyi könyvtárban található egy, vagy több git repository, amelyek logjait szeretnénk előkészíteni. Az argumentumok az *agrpase* modul segítségével veszem át, majd az *os* modul segítségével megváltoztatom a kívánt mappára a végrehajtás helyét, végül pedig a *subprocess* modul segítségével kiadom a `git log` parancsot, aminek kimenetén már könnyedén végrehajthattam a már implementált funkcionalitást, hogy előállítsam az eredményt. Az alkalmazás kimenete JSON formátumban készül, hiszen ezt mind előállítani mind feldolgozni egyszerű, és emberi szemmel könnyen ellenőrizhető, hogy helyes-e a működés.

Miután az alapvető funkciók készen voltak, a továbbhaladás előtt egység teszteket készítettem, az eddigi funkciók ellenőrzésére. A teszteket a `pytest` alkalmazás segítségével készítettem, és 90%-os lefedettséget értem. Annak érdekében, hogy a helyes működést kellő rendszerességgel ellenőrizzem, illetve, hogy különböző Python verziókkal való kompatibilitást biztosítsuk, a travisCI[9] eszközt alkalmaztuk, ami lehetővé teszi, hogy minden commit után több Python verzión lefussanak a tesztek.

A tesztek elkészülése után, az eszköz készen állt, arra hogy a CVE Miner használja. A fő eszköz telepítésének egyszerűsítése végett, modult készítettem belőle. A modult a PyPi[10] oldalra töltöttem fel, ahonnan a projekt készítése során használt csomag kezelő (pip), el tudja érni.[11]

A fő eszköz fejlesztése során felmerült az igény, hogy a Parser képes legyen a változott sorok és fájlok számát is megtalálni. Ez az információ alapvetően nem része a logoknak, így az egymást követő commitok közötti különbség kiszámításával szükséges őket előállítani. A `git dif` parancsot használtam, ami két tetszőleges commitot vet össze, és megadja a különbségeket közöttük. Mivel a `git log` parancs időrendi sorrendben adja meg a commitokkal kapcsolatos információkat, így elég sorban végigmenni egy ezeket tartalmazó listán, és páronként összehasonlítani őket.

A megközelítéssel kapcsolatban több probléma is felmerült, először is jelentősen lelassította az eszköz futását, hiszen rengeteg további műveletet igényelt. A lassulás mértékének csökkentésének érdekében ezt a szakaszt párhuzamosítottam, hiszen a különbségek nem épülnek egymásra. Pythonban ezt a *ThreadPoolExecutor* osztály teszi lehetővé, ami a szálak kezelését elfedve, biztosítja az egyszerű és gyors kezelését a tetszőlegesen sok párhuzamosan elvégzendő feladat helyes beosztásának. A súlyosabb hiba azonban a merge commitokkal volt kapcsolatos, azaz olyan commitokkal, amik 2 vagy több szülővel is rendelkeznek. Ezeknek az esetében ez a változtatás számítás helytelen, mivel csak egyetlen szülő committal hasonlítja össze őket, amiből az összesítés során nem feltétlenül használnak fel mindent, tehát pontatlan eredmények születnek. A merge commitok értékeinek előállításához számos egyéb megoldás kipróbálása után, végül szükséges volt

[9] `https://www.travis-ci.com/`
[10] `https://pypi.org`
[11] `https://pypi.org/project/gitlogparser`

a GitHub API-t[12] használni.

4.1. Kódrészlet. GitHub API kapcsolat létrehozási a Git Log Parserben

```
url = subprocess.getoutput('git config ––get remote.origin.url').split('.')[1]
url = list(filter(None, url.split('/')))
url = url[−2] + '/' + url[−1]
repo = Github(github_token).get_repo(url)
```

A repository, API-n keresztüli eléréséhez szükség van egy URL-re, aminek segítségével beazonosítható a projekt, ennek előkészítését a 4.1. kódrészletben láthatjuk. Miután az elérési cím készen van, létre kell hozni egy kapcsolatot az API-val. Az API kezelésére használt csomag[13] segítségével, egy GitHub token megadása mellett, kapcsolatot hozok létre, majd a kapcsolatot használva előkészítem a repository adatait.

Egy GitHub token[14] egy egyszerű módja, hogy az azt generáló felhasználó fiókjához kapcsolhassuk a végzett műveleteket, hasonló módon, mintha be lennénk jelentkezve a felhasználói fiókjukba. Amikor a felhasználó ezeket létrehozza limitálhatja a token birtokában elvégezhető műveleteket, így biztos lehet abban, hogy a tokennel nem, vagy csak nagyon limitáltan lehet visszaélni.

Az API használata csak további nehézségekhez vezetett, hiszen mindössze 1000 kérést lehet hozzá intézni óránként, ami napokra is emelhette volna a futásidőt. A futási sebesség maximalizálása végett, úgy döntöttem, hogy a parser ezt a feladatot hárítsa a CVE Minerre, és csak jelölje meg a merge commitokat. A teljesítmény növekedés jelentős, hiszen a merge commitok csak kis része érintett CVE javításokban, és ezeknek elég ismerni a változtatási adatait.

A 4.2. kódrészletben látható a változtatási statisztikákat készítő függvény. Mivel a Parser önálló eszközként is használható, a merge commitok változtatásainak kigyűjtése opcionálisan továbbra is elérhető.

[12] https://docs.github.com/en/rest
[13] https://pypi.org/project/github.py/
[14] https://docs.github.com/en/actions/reference/authentication-in-a-workflow

4.2. Kódrészlet. A változtatási statisztikákat gyűjtő függvény

```
def mine_stats(commit_hash, gitObj=None, isMerge=False, sleep_amount=0):
    if gitObj is not None and isMerge:
        time.sleep(sleep_amount)
        commit = gitObj.get_commit(sha=commit_hash)
        return [
            len(commit.files),
            commit.stats.additions,
            commit.stats.deletions
        ]
    else:
        parent = subprocess.getoutput(
        'git log --pretty=%P -1 ' + commit_hash
        )
        return subprocess.getoutput(
        'git diff ' + parent + ' ' + commit_hash + ' --shortstat'
        )
```

4.3. CVE Miner

4.3.1. Működés

A projektünk fő eszköze a CVE Miner, ami felhasználja az előző két alprogramot, illetve további funkciókkal egészíti ki őket. Az alkalmazás működését a a 4.2 ábra illusztrálja.

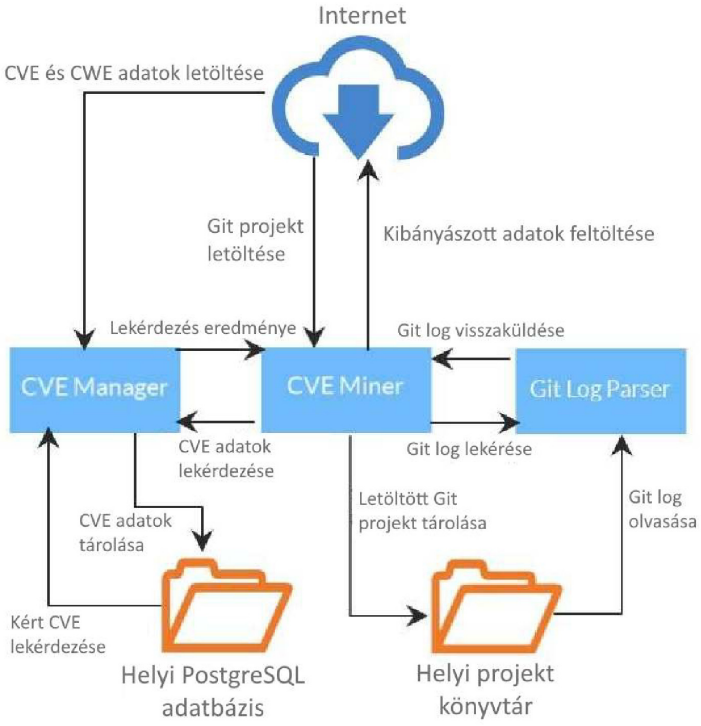

4.2. ábra. Az alkalmazás működése

A program működéséhez néhány előzetes beállítás szükséges. Itt meg kell adnunk az utat, ahova a CVE Manager letölti a szükséges adatokat, illetve a helyi adatbázishoz tartozó hozzáférési adatokat. A CVE Manager ezek után előkészíti a helyi adatbázist a későbbi használatra.

A program működése során a parancssorban meg kell adnunk a feldolgozni kívánt projekt helyi vagy online elérési útját, de akár egy JSON fájlt is megadhatunk, ami több projektet tartalmaz. Ha a projekt nem lokálisan elérhető, akkor a CVE Miner letölti. Ezek után a CVE Miner elindítja a Git Log Parsert, ami legenerál egy ideiglenes JSON fájlt. Ezt a program beolvassa, és átnézi a commitokhoz tartozó üzenetet, azt figyelve, hogy van-e CVE említés az üzenetekben. Az alkalmazás egy-egy CVE első és utolsó említését tárolja közvetlenül, hiszen ezek tartalmazzák a legtöbb információt, a köztes említések adatait utólag számítjuk ki ezek alapján. A program a CVE Manageren keresztül lekérdezi a talált CVE-hez tartozó fontosabb adatokat. Ilyenek például a publikálás dátuma, a hiba súlyossága, illetve az, hogy melyik CWE csoportba tartozik.

A következő lépés a statisztikák készítése. Minden feldolgozott projektről készül egy JSON fájl, ami többféle statisztikát tartalmaz. Az egyik csoport a CVE-kre lebontott statisztikák. Ide tartoznak a korábban kibányászott adatok mint a súlyosság, illetve az első és utolsó említés között eltelt idő és a commitok száma. A másik csoport a projektre vonatkozó statisztikák, amik létrehozásához a NumPy[15] Python csomagot használtuk. Ide tartoznak különböző korrelációk (idő és súlyosság, megváltozott kódsorok száma és súlyosság, illetve megváltozott fájlok száma és súlyosság közötti korrelációk) és átlagok (első és utolsó említések között eltelt átlagos idő, megváltozott kódsorok és fájlok átlagos száma). Ezek után, amennyiben a megfelelő kapcsolót megadtuk, az adatok felkerülnek egy Airtable [16] adatbázisba. Ha nem adjuk meg, akkor csak helyi JSON fájlok készülnek róluk. A harmadik csoportba tartozó statisztikák az adatbázisbeli adatokból jönnek létre. Ezek az egyes nyelvekre lebontott statisztikák. Itt ugyanazokat a korrelációkat és átlagokat számolja a program mint a projektek esetében, de kiegészíti őket szórással és mediánnal is. Ha esetleg valamiért az Airtable nem megfelelő, akkor egy másik kapcsoló megadásával lehetőség van létrehozni egy helyi PostgreSQL adatbázist, ahova a program

[15] `https://numpy.org/`
[16] `https://airtable.com/product`

minden adatot feltölt.

4.3.2. Fejlesztési folyamat

A CVE miner fejlesztését azzal kezdtem, hogy képessé tettem rá, hogy a kívánt projekteket helyesen átvizsgálja a Git Log Parser használatával, és ennek eredményeit beolvassa, eltárolja.

Mivel a Git Log Parser egy útvonalat vár, a CVE Miner ha útvonalat kap, azt egyszerűen továbbadja a parsernek, azonban itt már fontos volt, hogy lehetőség legyen arra is, hogy online elérhetőségek alapján kezdődjön meg a bányászás, és ne kelljen külön előre letölteni a kívánt projekteket. Ha a miner egy letöltési linket kap egy projekthez, akkor azt automatikusan letölti, előállít hozzá egy relatív útvonalat, és ezt adja tovább a parsernek. A megadott elérhetőség típusát előre kell jelezni, egy paraméterrel, abban az esetben, ha az online elérhetőséghez tartozó kapcsolót adjuk meg, az eszköz feltételezi, hogy egy linket kapott, aminek segítségével képes egy egyszerű `git clone + kapott link` parancs kiadásával, ezért a *subprocess* modul segítségével egyszerűen kiadja ezt a parancsot. Ha a parancs kiadása után nem jön létre a megfelelő nevű mappa, akkor tudja, hogy hiba történt, és egy kivétellel visszatér, ha pedig sikerült elkészítenie a megfelelő mappát, annak elérését egyszerűen továbbadhatja a Parsernek. Ebben a folyamatban felmerültek akadályok, hiszen a Parser a beneteket parancssori argumentumként várja, annak érdekében, hogy ne kelljen jelentős változtatásokat végezni a Parseren, létrehoztam egy osztályt, ami a megfelelő változókkal rendelkezik, mivel a Python nem erősen típusos nyelv, nem jelent problémát, hogy ez az osztály nem az *argparse* osztály leszármazottja.

A CVE Miner esetében már a fejlesztés elején készítettem teszteket, és ezeket folyamatosan a fejlesztéssel párhuzamosan frissítettem. A teszteket a osztályokra bontottam aszerint, hogy melyik osztályt tesztelik, hogy jobban elkülönüljenek egymástól, és könnyebben be lehessen azonosítani őket. Ezeket ezúttal, akár csak a Git Log Parsernél, a travis CI folyamatos integrációs eszköz futtatja, ezzel elősegítve a kompatibilitási problémák felfedezését.

Miután a tesztelési környezet készen állt, és a kezdeti tesztek elkészültek, a CVE Miner a Git Log Parserrel történő kommunikációját véglegesítettem. A miner már nem csak elindítani tudta a Parsert a megfelelő helyen, hanem a kimenetét is be tudta olvasni, ezt

egyszerűen a *json* modul *load* függvényével hajtottam végre. Mivel a kimenet fájlként jön létre, ezt miután már nincs rá szükség a Miner eltávolítja, az *os* modul felhasználásával, hogy később ne okozzon problémát.

A commit információk beolvasása után, a kézenfekvő közvetkező lépés azt volt, hogy elkészítsem a CVE kereső mechanizmust. Egy egyszerű szöveges illesztés mellett döntöttem, ami megvizsgálja az adott commit üzenetét, hogy tartalmaz-e CVE említést, egy reguláris kifejezés illesztés segítségével. Ha talál ilyet, akkor a commitot egy szótárba teszi, ahol a hozzá tartozó kulcs a CVE azonosítója lesz, és feljegyzi, mint első, és utolsó említést. További keresés során ha az adott CVE egy újabb említésébe fut, akkor az utolsó említést frissíti. A végeredmény egy szótár, amiben megtalálható a összes, az adott projektben talált CVE, és ezeknek első és utolsó említését tartalmazó commitok adatai. Mivel a detektálási feltétel szándékosan nem szigorú, hogy véletlenül se hagyjon el egyetlen említést sem, így elengedhetetlen a talált sérülékenységek helyességének ellenőrzése. Az ellenőrzést a CVE Manager segítségével végeztem el, és azokat a szótár bejegyzéseket, amelyek nem létező CVE-khez tartoznak elvetettem. Az így elkészült szótárat ideiglenesen JSON fájlba mentettem .

Az átmeneti JSON eredmények vizsgálata során több hiba is felszínre bukkant. Például, nem készítettem fel az eszközt üzenet nélküli commitok kezelésére, a dátum kezelési módszer amit alkalmaztam az első és utolsó commit között eltelt idő meghatározására nem volt kompatibilis az összes támogatott Pythons verzióval. A hibák elhárítása nem jelentett jelentős technológiai kihívást, hiszen, csak fel kellett készítenem az eszközt szélsőséges esetekre, amikre alapból nem számítottam.

A hibák javítása és a tesztek frissítése után az eszköz készen állt arra, hogy bevessük. Nem volt hozzáférésünk tradicionális online adatbázisokhoz, így az eredményeket az AirTable[17] online adat tároló eszközbe töltöttük fel, hogy meg tudjuk őket osztani egymás között.

Az első tesztkörök után láthatóvá vált, hogy az eszköz működik, azonban felmerült az igény, hogy az adott sérülékenység javítási adatait, hány sor/fájl módosításból javították meg, is gyűjtsük ki. Miután a Git Log Parsert felkészítettem erre a feladatra, azzal szembesültünk, hogy túl sok merge commit van, és mivel ezek adatainak megszerzéséhez

[17] `https://airtable.com/`

a GitHub API használatát nem sikerült elkerülnöm, tarthatatlanul lelassult a bányászási folyamat.

Mivel a Parser nem tud döntést hozni arról, hogy mely commitok információira van szükségünk, ezt a funkciót részben átköltöztettem a Minerbe. A Parser kihagyja a merge commitokat, és csak megjelöli őket, későbbi feldolgozásra. Mivel a Miner már tudja, hogy melyik commitok tartalmaznak értékes információt, elég csak azokhoz a merge commitokhoz megszereznie a módosítási adatokat, amelyek érintettek valamelyik CVE-vel kapcsolatban, ami szinte elhanyagolhatóra csökkenti az API-val való kommunikációt, és az ezzel járó teljesítmény vesztést is.

A futás során a Miner két környezeti változót állít be, az egyik értéke a felhasználó GitHub tokenje, amelyet indításkor szükséges megadni, illetve az adott repository elérhetősége, amit a bányászás kezdetekor tárol el. Ezek segítségével képes kapcsolatot létrehozni a GitHub API-val, és az adott commit-hoz tartozó változtatási adatokat letölteni. A kapcsolat létrehozásának megvalósítása a 4.3. kódrészletben látható.

4.3. Kódrészlet. A merge változtatási adatok gyűjtése a CVE Minerben

```
repo = Github(
        os.environ['GITHUBTOKEN']
        ).get_repo(os.environ['REPO_URL'])
...
elif commit['isMerge']:
   try:
      response = repo.get_commit(sha=commit['commit_hash'])
      commit['insertions'] = response.stats.additions
      commit['deletions'] = response.stats.deletions
      commit['files_changed'] = len(response.files)
  ...
...
```

4.4. Vizsgált adathalmaz

Minden bányászási eszközhöz tartoznia kell egy vizsgált adathalmaznak, hiszen egy ilyen eszköz legjobb esetben annyi információt képes kinyerni, amennyi a forrásaiban alapvetően elérhető. Emiatt a vizsgált adatok minőség legalább annyira fontos mint maga az eszköz, így fontos volt, hogy az információban lehető leggazdagabb projekteket vizsgáljuk.

A GHTorrent-en elérhető adatok tökéletesen megfeleltek a céljainknak, hiszen fel-

használásukhoz nincs szükség a mindenki számára elérhető felületek használatán kívül semmire, ezáltal lehetővé téve nagyszámú projekt vizsgálatát, úgy, hogy a legtöbb esetben ne legyen hozzáférési akadály. Az adatbázis nyíltan elérhető bárki számára, azonban mérete miatt nem volt lehetőség helyileg üzembe helyezni, azonban a BigQuery-n tárolt verzióhoz hozzáférést engednek bárkinek, akinek van előfizetése.

A mindenki számára biztosított próbaverziót használva lehetőségem volt a BigQuery akadálytalan használatára, azzal együtt is, hogy egy másolatot kellett készítenem az adatokról. Az eszköz a GHTorrentnél jóval nagyobb adatbázisok kezeléséhez készült, emiatt egy ilyen viszonylag kicsi adathalmazon gyorsan és egyszerűen tudtam vele lekérdezéseket végezni. Az én felhasználási esetemben nem sokban tér el egy relációs adatbázis kezelésétől, így nem jelentett komoly nehézséget az adatok kiszűrése.

Nyelvenként 500 projektet választottam ki, annak érdekében, hogy ez a viszonylag kicsi minta halmaz a lehető legértékesebb információkat tartalmazza népszerűségi sorrendbe állítottam őket. Mivel ilyen statisztika konkrétan nincs, így a GitHub csillagok[18] számát vettem alapul, ez a szám lényegében azt jelenti, hogy hányan mentették el maguknak az adott projektet, ezáltal valamelyest jelölve annak népszerűségét. A nyelvek legtöbb csillaggal rendelkező projektjeit JSON fájlként elmentettem, emiatt nem lehetett dinamikus állítani az elérhető projektek számát, és a bányászás megkezdéséhez több külső fájl is szükségessé vált, viszont nem vált szükségessé a BigQuery API használata.

[18] `https://docs.github.com/en/github/getting-started-with-github/saving-repositories-with-stars`

5. fejezet

Eredmények

Ebben a fejezetben ismertetjük a kutatásunk eredményeit. Az alábbiakban közöltek nem jellemzik a nyelveket általánosságban, hiszen ahhoz túl kicsit a vizsgált projektek száma, hanem inkább a népszerűbb GitHub projektekről vonhatunk le általánosabb következtetéseket.

5.1. CVE előfordulások

Annak érdekében, hogy a későbbi statisztikákat a megfelelő kontextusba tudjuk helyezni elengedhetetlen, hogy tudjuk, pontosan hány projektről beszélünk nyelvenként. Minden nyelvhez 500 projektet néztünk át mint ahogy ezt a 5.1 láthatjuk is.

Jól látható, hogy komoly eltérések vannak a projektenkénti CVE-k számának terén, Scheme-ben például mindössze 8 projektben találtunk említést, de így is több darabot, mint minden más nyelv esetében. Ennek oka, hogy itt elsősorban csomag kezelő alkalmazásokat ellenőriztünk, amelyeknek rendkívül sok külső sérülékenységre kell reagálniuk. A legnagyobb CVE előfordulási aránnyal a Python rendelkezik, itt a projektek 18 százalékában találtunk legalább 1 említést. Számos ok állhat e mögött, ezek közül a legvalószínűbb, hogy a Python egy fiatalabb, feltörekvőben lévő nyelv, ebből kifolyólag a fejlesztési folyamatnak szervesebb részévé válhatnak a modern megközelítések, mint például a CVE-k kezelése, és rögzítése.

Nyelv	CVE említést tartalmazó projektek száma	CVE említést tartalmazó projektek aránya	CVE említések száma
BitBake	29	5.8%	1028
C	51	10.2%	1476
C++	54	10.8%	709
Go	50	10%	245
Java	44	8.8%	210
JavaScript	21	4.2%	115
PHP	61	12.2%	133
Python	92	18.4%	317
Ruby	86	17.2%	1505
Scheme	8	1.6%	2180

5.1. táblázat. A CVE előfordulásokkal kapcsolatos adatok

5.2. Eltelt idővel kapcsolatos statisztikák

Átlagos idő egy hiba első és utolsó említése között Ez a statisztika több dolgot is megmutathat egy adott programozási nyelven fejlesztő közösség tendenciáival kapcsolatban. A legkézenfekvőbb jelentésük, hogy mennyi idő egy hibát átlagosan kijavítani. Ez nem pontos statisztika, hiszen, arra nincs mód, hogy megtudjuk mikor vettek észre egy adott hibát és kezdtek el dolgozni a javításán, viszont az arányok mutatására így is alkalmas. Előfordulhat, hogy egy CVE többször is meg van említve, ennek leggyakoribb oka, hogy a javító kód később lett a központi fejlesztési ágra bevéve. Ezt az esetet úgy vettük mintha a hiba a merge pillanatáig nem lenne javítva, hiszen hiába áll rendelkezésre egy potenciális megoldás, ha az éles verziónak nem része.

Egy másik leolvasható érték, hogy milyen gyakorisággal van szükség később visszatérni egy-egy hiba javításához. A merge-ek általában gyorsan történnek, 1-2 hétnél nem tartanak tovább, hiszen ekkorra már a hiba közismert, és kihasználható. Előfordulhat, hogy akár hónapokkal később a fejlesztők felfedeznek egy jobb megoldást a problémára, és lecserélik a korábbi implementációt. Ritka esetekben az is megtörténhet, hogy

a probléma kiküszöbölése során további hibákat hoznak létre, amik megoldásához újra foglalkozni kell a korábban írt kóddal.

Az ezzel kapcsolatos eredményeink az 5.1. ábrán láthatóak.

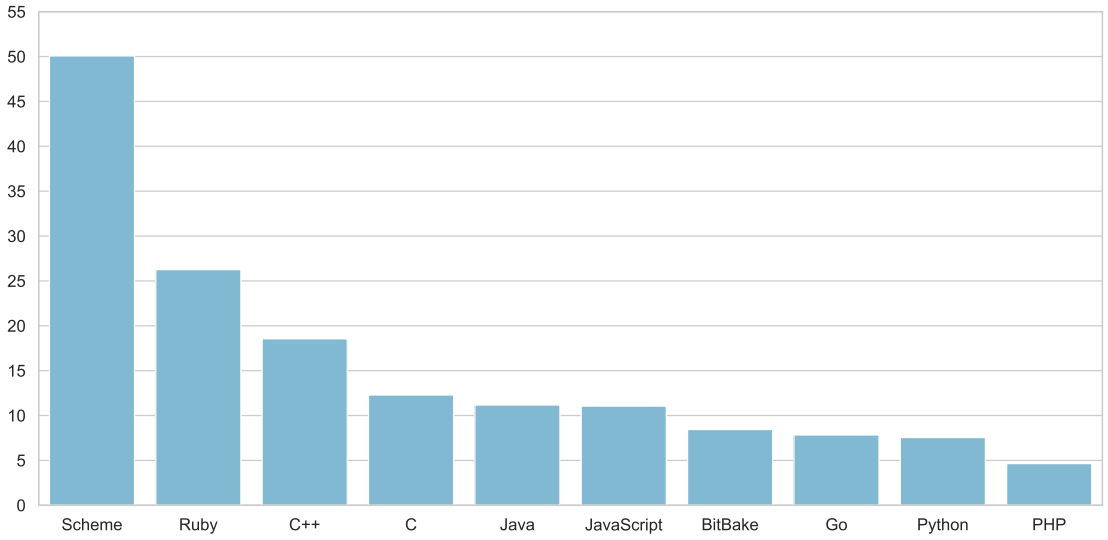

5.1. ábra. Az átlagos eltelt idő egy CVE első és utolsó említése között napokban

Átlagos eltelt idő egy CVE publikációja és javítása között A legtöbb CVE javítás átterjedő hibákból ered, azaz egy kisebb projekt egy nagyobbat használ függőségként, vagy fordítva, ekkor a függőség hibája javításra kerül a használóban is, legtöbb esetben egy egyszerű verziófrissítés keretein belül. Ezekben az esetekben a javítás csak a CVE publikációja után lehetséges. A forrás projektekben nagyon ritkán fordul elő, hogy a hivatalos publikáció után említenék a hibát, hiszen senki nem publikálna egy komoly sérülékenységet, amit nem tudnak javítani. A függő projektekben természetesen szinte minden CVE javítás a publikáció után történik. Előfordul azonban, hogy a tudatos verziófrissítés korábban történik meg, ami annak a következménye, hogy a nagyobb nyitott forrású projekteknek léteznek saját önálló módjai arra, hogy a komoly sérülékenységekről és azoknak javításáról értesítse a felhasználóikat.

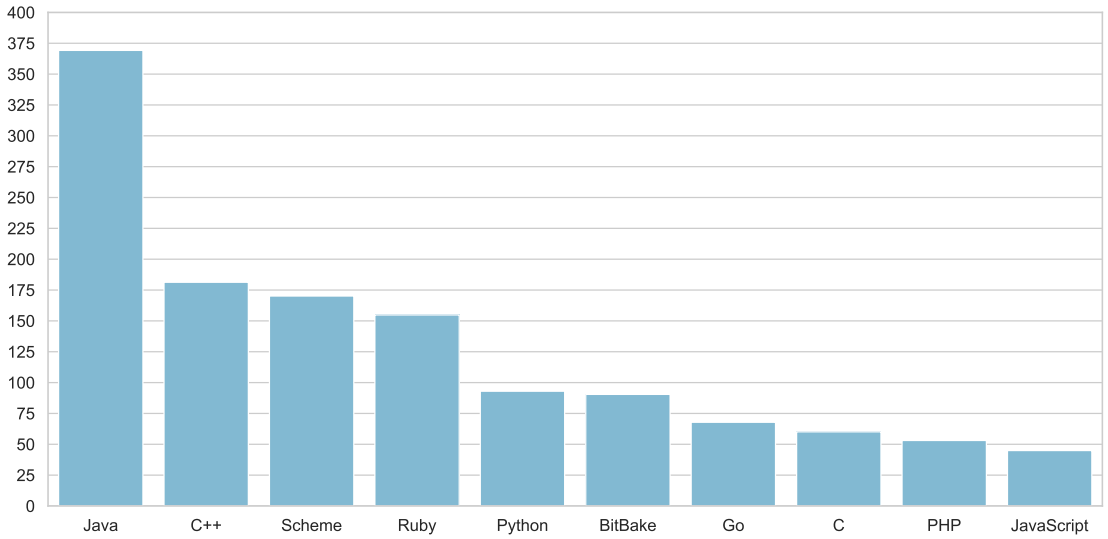

5.2. ábra. Az átlagos eltelt idő egy CVE publikációja és utolsó említése között napokban

Az 5.2. ábrán megtekinthető a publikációtól eltelt átlagos idő napokban nyelvekre bontva. Az itt látható értékek lényegesen nagyobbak mint az 5.1. ábrás láthatóak, ennek elsődleges oka, hogy egy CVE gyanús sérülékenységet csak a publikáció után neveznek hivatalosan annak. A második legvalószínűbb indok, a fent említett probléma, miszerint a függő programok csak a publikáció után tudják javítani az így felmerülő hibákat.

5.3. Aktivitás alapú statisztikák

Aktív fejlesztők száma egy CVE javítása alatt A fejlesztők száma egy hasznos kiegészítő statisztika. Jellemzi, az átlagos aktivitást a vizsgált nyelvekben, ami segíthet jobban kontextusba helyezni a korábbi statisztikákat. Például, ha egy CVE jelenléti idejében kevesen aktívak, és a javítás sokáig tart, egy kevésbé menedzselt projektről beszélünk, azonban ha kevés fejlesztő gyorsan javít átlagosan, az egy gyors és hatékony közösségről árulkodik.

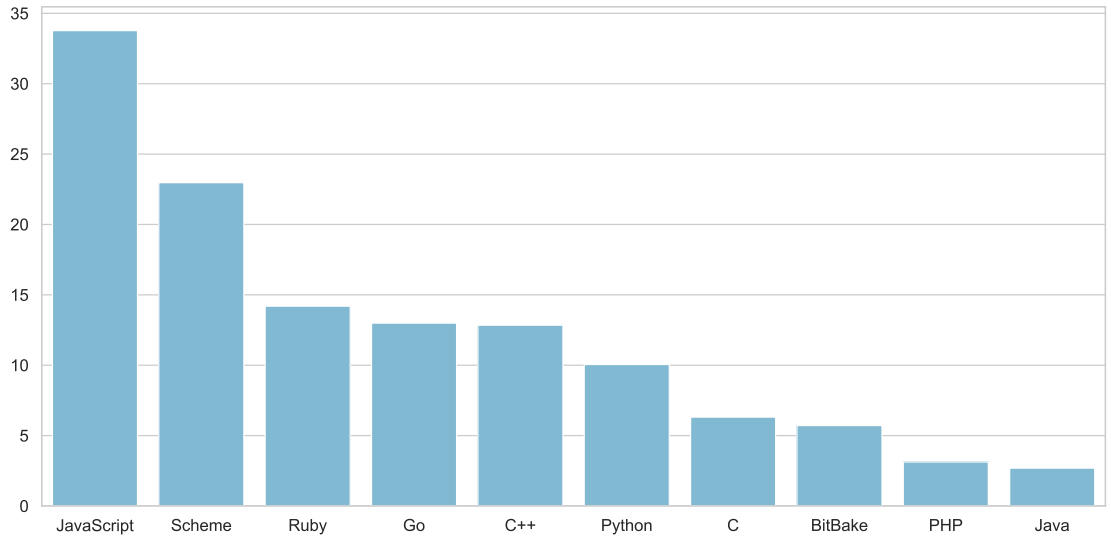

5.3. ábra. Az aktív fejlesztők átlagos száma

Az 5.3. ábra további kontextust biztosít a korábbi statisztikákhoz, illetve indoklásként szolgál az eddigi eredményekhez. Az általunk vizsgált adatok alapján például Java-ban átlagosan majdnem kétszer annyi ideig tartott egy hiba javítása a publikációjától számítva (lásd 5.2), mint C++-ban, de átlagosan sokkal kevesebben is dolgoztak rajta. További példaként megfigyelhető a JavaScript, ami mindkét idő alapú statisztikában jobb eredményeket mutat, mint a legtöbb vizsgált nyelv, ami valószínűleg a kiemelkedő számú aktív fejlesztőnek köszönhető.

CVE javítása alatt keletkező commitok száma A commitok száma hasonló információkkal láthat el mint a fejlesztők száma, azonban kicsit más fókusszal, ugyanis egyetlen fejlesztő készíthet több commitot is, ennek eredményeként a commitok, sokkal inkább a fejlesztés sebességét jellemzik. Ha egy nyelvben hosszú időn keresztül aktívak a CVE-k és átlagosan kevés fejlesztő dolgozik rajta, alacsony commit számmal, az arra enged következtetni, hogy a vizsgált projektek nem feltétlenül aktívak. Természetesen aktívabb projektekkel rendelkező nyelvben is előfordulhatnak hasonló statisztikák, hiszen ez a statisztika nem veszi figyelembe a commitok méretét. Ha egy projektben kevesebb, de nagy méretű és hatású commit készül, nem nevezhető kevésbé aktívnak mint egy olyan, amiben sok de marginális változtatásokat tartalmazó commit található.

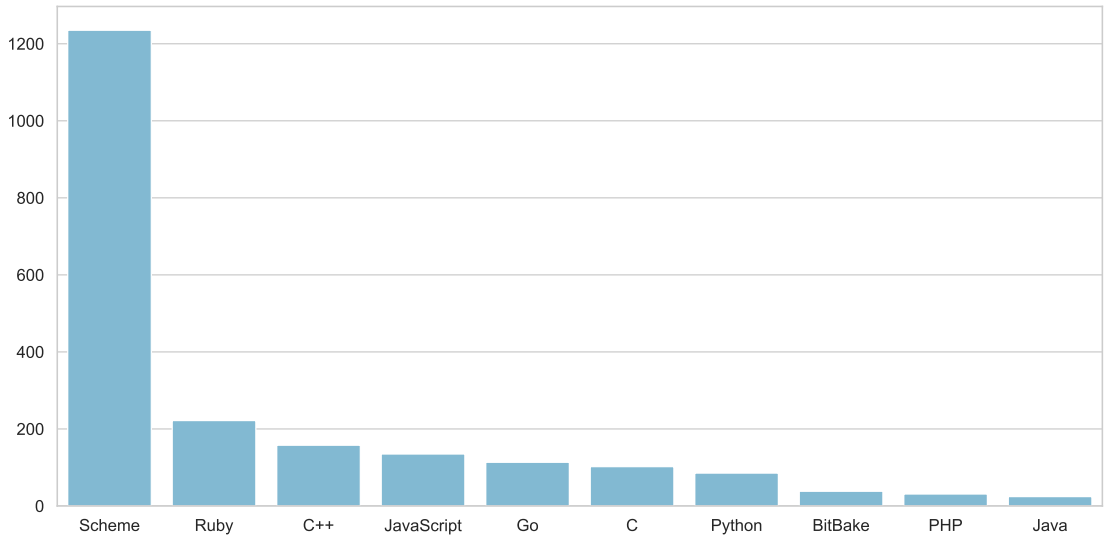

5.4. ábra. Átlagos commit szám

Az 5.4. ábrán látható, hogy a mintákban jelentős eltérés tapasztalható az elkészült commitok száma között. A Scheme projektjeiben például rengeteg commit készül, és viszonylag sok az aktív fejlesztő mialatt egy CVE aktív, ennek ellenére aránylag lassú a válaszidő a sérülékenységekre.

5.4. Átlagos fájl és sor változtatások

Az átlagos fájl és sor változtatások azt mutatják, hogy egy átlagos CVE mekkora hatást gyakorolt az adott nyelvek projektjeire. Ezt rengeteg faktor befolyásolja, nem csak nyelvi, de projekt szinten is. Különböző fejlesztési konvenciók komolyan módosíthatják az itt mutatott átlagokat.

Átlagos fájl módosítások commitonként nyelvekre bontva A fájl módosítások elsősorban a hibák kiterjedtségét jellemzik ideális esetben. Ha egy sérülékenység kiküszöböléséhez több fájl módosítására is szükség van, feltehető, hogy nagyobb részét érintette az adott projektnek. Természetesen ez nem minden esetben mondható el, hiszen erre nagy befolyása lehet az adott termék belső struktúrájának is. Ha a projekt összességében kevés fájlból áll, az átlagos módosítások száma valószínűleg kevesebb lesz, mint egy jobban szegmentáltnak.

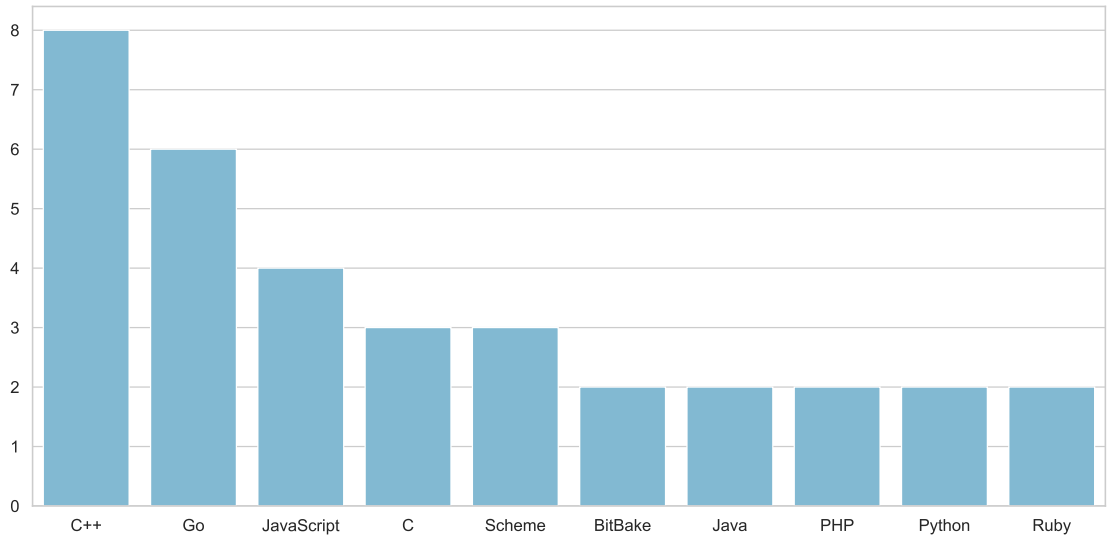

5.5. ábra. Átlagos fájl módosítások

Érdemes külön kiemelni itt a Go-t, ami az általunk vizsgált esetekben valóban a hibák kiterjedtsége miatt igényel ennyi fájl változtatást. A Go estében magában a nyelvben előfordulnak CVE-k, amik hatására a fejlesztők kénytelenek újabb nyelvi verziókra frissíteni a projektjeiket, ami rengeteg fájl módosításával járhat. C++-ban viszont a kiemelkedő szám nem feltétlenül a hibák típusából ered, hanem a vizsgált projektek szokásaiból. Gyakran előfordul, hogy a CVE-ket csak egy-egy nagyobb kiadás alkalmával nevezik meg, így egy commit nagy mennyiségű fájlváltozással jár.

Átlagos sor módosítások commitonként nyelvekre bontva A sor módosításokat az eltávolított, és hozzáadott sorok összegeként értelmeztük, ami ahhoz vezet, hogy ha jelentős mennyiségű létező kód módosul, az átlag lényegesen jobban romlik, mintha ugyanannyi új sort adtak volna hozzá. Ennek oka az, hogy a git egy sor módosítását néha úgy érzékeli mintha kitöröltük volna az egész sort, és újra írtuk volna a módosításokkal kiegészítve, tehát összesen két sort változtattunk.

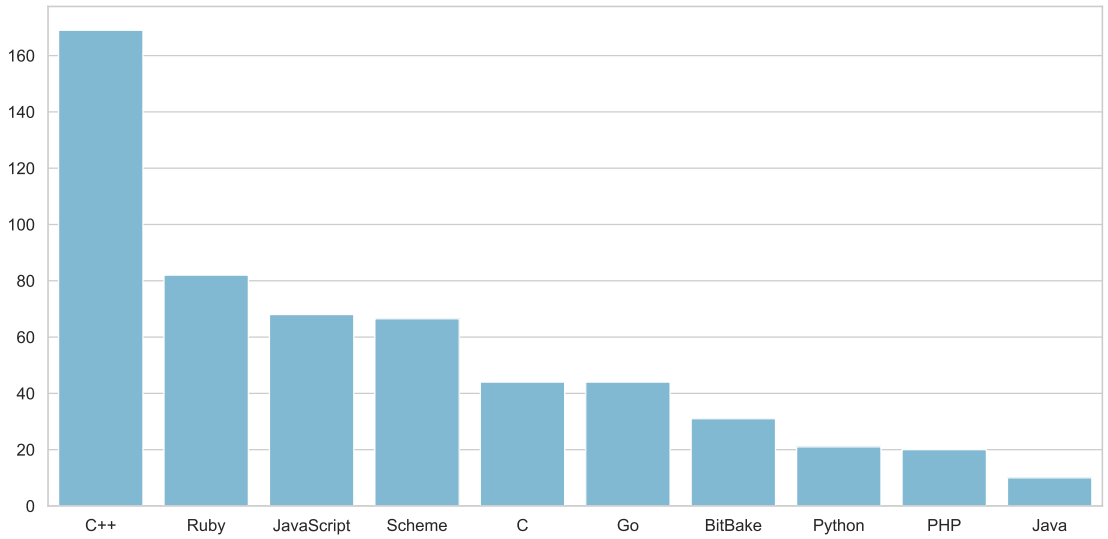

5.6. ábra. Átlagos sor módosítások

Az itteni adatok tovább árnyalják a korábbi eredményeket, hiszen említettük, hogy előfordulhat, hogy kevés de hosszú commit készül egy projekt fejlesztése során. Az 5.6. ábrán láthatóak ezek az adatok. Itt ismét kiemelkedő értékekkel rendelkezik a C++, aminek okait korábban már tárgyaltuk. A Go-val kapcsolatos állításainkat is jól szemlélteti ez az eredmény, hiszen az új nyelvi verzióra való frissítés általában kevesebb sor- és több fájlmódosítást igényel.

5.5. CWE-kkel kapcsolatos statisztikák

A CWE-k csoportosítások a CVE-k számára, általánosabban foglalják össze a hiba típusát, például memória szivárgás, SQL injekció, stb. Ezek segítségével lehetőségünk van arra, hogy lényegében átkonvertáltjuk a specifikus hibajavításokról létrehozott adatainkat, és hibatípusok javítási adataira általánosítsuk őket. Ezek segítségével magasabb szintű megállapításokat tehetünk az egyes nyelvek gyakori hibatípusaira vonatkozóan.

A leggyakoribb CWE-k nyelvenként Egy nyelv leggyakoribb hibáinak megismerése hasznára lehet mind fejlesztőknek mind szoftverfejlesztő cégeknek a hibák és sérülékenységek felkutatásába fektetett erőforrások optimálisabb elosztásában, illetve az elkerülésükben. Habár az adathalmazunk nem elég nagy ah-

hoz, hogy indikatív legyen a nyelvekről általánosságban, arra több mint alkalmas, hogy betekintést nyerjünk a különböző nyelvekre jellemző tendenciákba.

5.2. táblázat. Legygyakoribb CWE-k nyelvenként

Nyelv	CWE	Százalék
BitBake	CWE-119	19.41%
	CWE-125	13.32%
	CWE-20	11.67%
Go	CWE-400	17.55%
	CWE-20	9.30%
	CWE-295	8.16%
Python	CWE-20	17.35%
	CWE-200	9.46%
	CWE-79	5.99%
Java	CWE-502	13.87%
	CWE-119	11.48%
	CWE-20	8.61%
	CWE-200	5.74%
	CWE-79	5.62%
	CWE-400	5.26%
JavaScript	CWE-400	14.78%
	CWE-20	12.17%
	CWE-200	9.56%
	CWE-79	6.95%
	CWE-119	6.08%

Nyelv	CWE	Százalék
C	CWE-119	17.68%
	CWE-125	15.78%
	CWE-200	7.18%
	CWE-20	8.00%
C++	CWE-119	55.93%
	CWE-20	6.35%
	CWE-200	6.21%
Ruby	CWE-119	13.51%
	CWE-20	11.98%
	CWE-79	8.18%
	CWE-22	6.39%
Scheme	CWE-119	23.86%
	CWE-20	7.69%
	CWE-416	6.81%
	CWE-125	6.17%
PHP	CWE-79	18.79%
	CWE-352	11.28%
	CWE-20	11.27%
	CWE-77	6.76%
	CWE-89	6.67%

A 5.2 táblázatban láthatóak a leggyakoribb CWE-k nyelvenként. Itt csak azokat tüntettük fel, amik több mint 5 százalékos prevalenciával fordulnak elő, hiszen azok a sérülékenységi osztályok, amik ennél ritkábban fordulnak elő, nem nevezhetőek jellemzőnek. Az általunk vizsgált adathalmaz azt mutatja, hogy a legtöbb nyelvnek van 1-2 kiemelkedő hiba típusa. Az előfordulás aránya változékony, C++ esetében például a CWE-119[1] messze a legjellemzőbb, viszont például Java-ban a leggyakoribb hiba típusok nem nyomják el teljesen a többit, maximum 14 százalékos jelenléttel rendelkeznek.

A sérülékenységek eloszlásában történő nyelvek közötti differencia mértéke lehet annak, hogy mennyire nehéz elkerülni őket. C++-ban közismert hibaforrás a memória nem megfelelő kezelése, ezt igazolja túlnyomó dominanciája az ezzel kapcsolatos hibáknak.

[1] Improper Restriction of Operations within the Bounds of a Memory Buffer

A tény, hogy a hibatípus jellemzősége ennyire közismert, és mégis ilyen sokszor fordul elő, arra enged következtetni, hogy aránytalanul nehéz elkerülni. A többi nyelvben nem látható ennyire kiemelkedő hiba, de ez bizonyos szempontból rosszabb is lehet, hiszen így nehezebb meghatározni, hogy mire a legfontosabb odafigyelni.

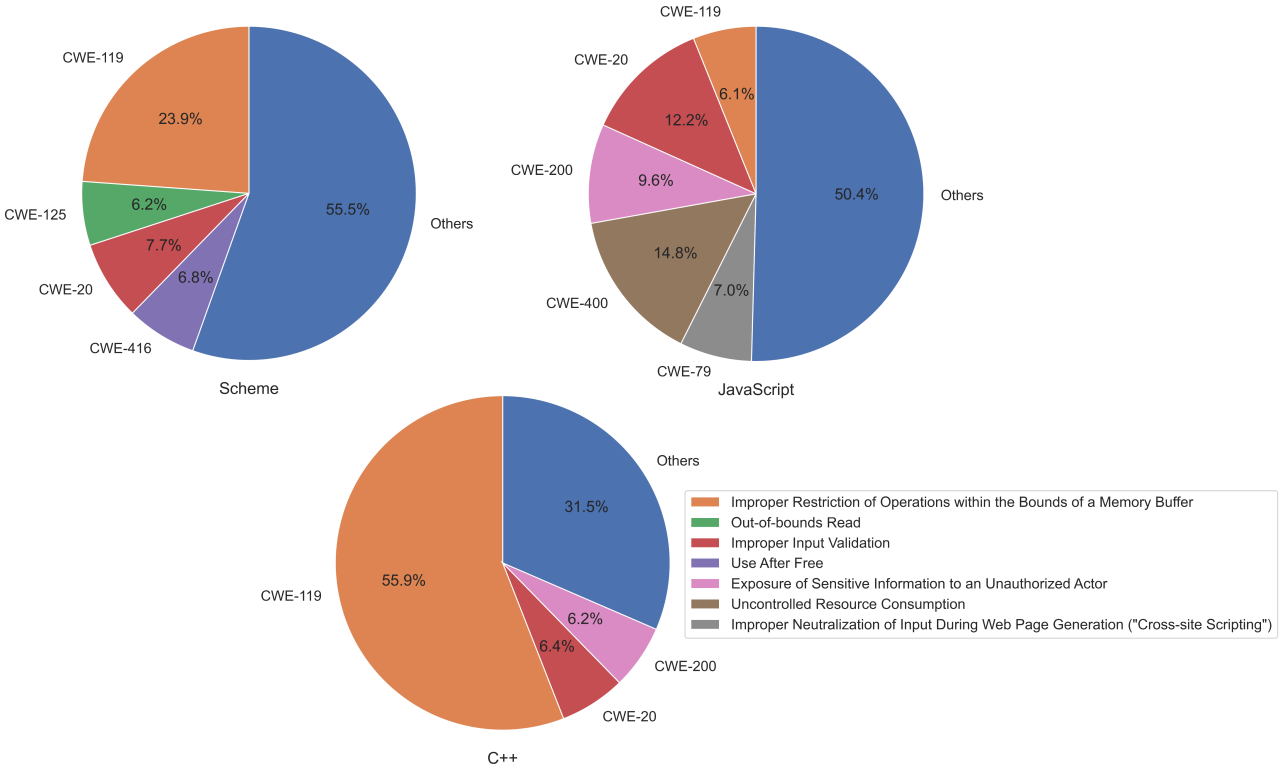

5.7. ábra. CWE vizualizáció (C++, JavaScript, Scheme)

A kördiagramok segítségével (5.7. ábra) vizualizáltuk a leggyakoribb CWE-ket C++-ban, JavaScript-ben, és Scheme-ben. Láthatjuk, hogy a C++ kivételével minden esetben, az előforduló CWE-k felét teszik ki a feltüntetettek.

5.6. CVE anomáliák, és okaik

Egy CVE mint korábban említettük, egy konkrét projekt hibája, és így az elvárt viselkedésük általánosan meg kellene egyezzen egy átlagos hibáéval. Csak 1 projektben kellene említve lennie, maximum 1-2 commit üzenetben kellene szerepelnie. Az utóbbi elvárás azért merülhet fel, mert nyílt forráskódú projektekről beszélünk, tehát ha egy részlegesen javított hiba túl hamar szivárog ki, könnyedén előfordulhatnak visszaélések. A CVE-k

előfordulások többsége ezeknek megfelelően viselkedik, így a kivételeket anomáliának nevezzük.

Az alábbiakban következő megállapításokat az anomáliák manuális vizsgálata során gyűjtött adatokra alapozzuk. Az ellenőrzés során a publikusan elérhető commit üzenetek tartalmára hagyatkozunk, ami nem tette lehetővé a teljes körű vizsgálatot, hiszen néhány, az eszközünk által megtalált commit privát láthatóságú volt, így nem fértünk hozzá további információhoz.

Többször említett CVE-k Több korábban említett statisztika is az ilyen esetekre vonatkozik, hiszen értékes információ szűrhető ki egy-egy hiba aktív időszakából, azonban egy CVE többszöri említése nem szokványos, ahogy ezt az előző bekezdésben említettük. Ennek ellenére gyakran előfordul, hogy többször említenek adott hibákat, erre a leggyakoribb indok, hogy a javítást előzőleges vizsgálatnak vetnek alá mielőtt az élő verzióba is beveszik. Az újbóli említések okai legtöbbször biztonsági szempontból jelentéktelenek, később teszteket készítenek a hiba újbóli előfordulásának elkerülésére, vagy régebbi verziókban is implementálják a javításokat. Ugyan ebbe a kategóriába sorolhatóak olyan esetek is ahol egy függőségben található sérülékenység ideiglenes kiküszöbölése érdekében átmeneti megoldásokat készítenek, amiket amikor a függőségben elkészültek a javítással kivesznek. Egy ilyen esetre a Tomcat[2] commitjai között találtunk példát. Az első üzenet amit az eszközünk észrevett már egy korábbi "workaround" (kerülő megoldás) javításához tartozik[3]. A második, és utolsó az eszközünk által felfedezett commmi során egy végső javítás kerül implementációra, ami a Java virtuális gép által biztosított megoldásokat implementálja[4]. Előfordul azonban olyan eset is, hogy egy hiba javítására készített módosítás egyéb funkciók hibás működését hozza magával, lényegében további hibákhoz vezet. Egy hiba köztes változtatások is során újra megjelenhet, ilyen eseményre példa a curl[5] esetében a CVE-2016-5419[6]. A hibát először 2016 augusztusában javították[7], 1 évvel az első commit után újból javításra szorul, ugyanis egy köztes verzió során ismét

[2] `http://tomcat.apache.org/`
[3] `https://github.com/apache/tomcat/commit/30af3f`
[4] `https://github.com/apache/tomcat/commit/b4e948`
[5] `https://curl.se/`
[6] `https://nvd.nist.gov/vuln/detail/CVE-2016-5419`
[7] `https://github.com/curl/curl/commit/247d890`

felbukkan a probléma[8].

Több projektben megemlített CVE-k Többször is említettük, hogy egy CVE egy adott termék hibája, ennek ellenére előfordul, hogy egy hiba több különböző projektben is meg van említve. A leggyakoribb indok erre a jelenségre a projektek egymástól való függése. Ha egy kódbázisban egy másik ettől függetlenül fejlesztett projekt funkcióit használják, azt függésnek nevezzük. A nyílt forráskódú fejlesztés során egyre többször fordul elő, hogy akár több száz más projekttel kerül egy szoftver függési viszonyban, közvetlenül vagy közvetetten. Az ilyen tömeges függés mellékhatásaként a különböző sérülékenységek képesek elterjedni, és egyszerre több projektre is hatással lenni. A legtöbb esetben a hiba javításra kerül a felhasznált projektben, így csak annak frissítésére van szükség, ekkor fordul elő, hogy az új verzió használatának indoklásaként említik az így kiküszöbölt CVE-t.

Hasonlóan viselkednek a forkok, illetve a nyelvi hibák. A lényegi különbség elágaztatott programok esetén, hogy a fejlesztők tudatosan használják egy jelentős részét egy másik kódbázisnak, így felkészültebbek a potenciális sérülékenységekre. A nyelvi hibák különlegesek abból a szempontból, hogy garantáltan minden azon a nyelven készített projektben javításra szorulnak, ezzel egy konkrét összehasonlítási lehetőséget biztosítva a különböző projektek között, mind sebesség mind dokumentáltság terén.

Mint láthatjuk a többszöri említéseket közös alapok, vagy függési viszonyok okozzák. Fontos észrevétel azonban, hogy nem feltétlenül említik a CVE-ket név szerint. Gyakran előfordul, hogy egy projektben egy használt modul frissítése során említenek egy CVE-t, azonban ezt a modul fejlesztői a javítás véglegesítése során nem teszik meg. Ennek eredményeként a CVE-k eredetének megállapítása nem minden esetben triviális a jelenlegi eszközünk eredményei alapján.

Rendhagyó CVE javítások Rendhagyónak olyan javításokat nevezünk, amelyek egyszerre több CVE említéssel rendelkeznek, vagy az átlagosnál jelentősen több sormódosítással bírnak. A két feltétel gyakran egyszerre fordul elő, ezek az esetek nem jeleznek meglepő viselkedést, egyszerre több hiba javítása természetesen az átlagosnál több sort

[8] `https://github.com/curl/curl/commit/33cfcfd`

igényel. Az ilyenek legtöbbször egy újabb verzió kiadásához történő előkészületek vagy egy korábbi kiadás komolyabb hibáinak utólagos javításának részei.

Olyan esetekben, amikor viszonylag kevés sorból több hibát javítanak, az általunk vizsgált összes alkalommal egy használt modul verziójának frissítése során került sor. A nagy sormódosítási igényt, várható módon, a javítások nehézsége okozta, ezek az esetek azonban olyan ritkák, hogy az általunk vizsgált kódhalmazban csak néhány példa található. Ezek közül egy a Hue[9] esetében fordul elő, itt habár 2 CVE-t javítanak egyszerre, a kettőhöz együttesen szükséges módosítások száma jelentősen meghaladja az átlagot[10].

[9] `https://gethue.com/`
[10] `https://github.com/cloudera/hue/commit/bf22469`

6. fejezet

Konklúzió

Jelen dolgozat és kutatás célja az volt, hogy megvizsgáljuk, hogy vannak-e nyelvekre jellemző minták CVE-kkel és CWE-kkel kapcsolatban. Ennek eléréséhez készítettünk, illetve továbbfejlesztettünk 3 eszközt, amelyek együttes működtetésével létrehoztunk egy adathalmazt a népszerűbb nyílt forráskódú projektek ezekkel kapcsolatos adatairól. Az adatok közül több százat manuálisan ellenőriztünk, és mind helyesnek bizonyult. Ezek után részben kézzel, részben automatizált módszerekkel statisztikákat készítettünk, amelyek betekintést engednek a sérülékenységek ellen folytatott küzdelembe.

Eredményeink többek közt azt mutatják, hogy általánosan aktívabb közösségek nem feltétlenül hatékonyabbak a hibák kiküszöbölésében. A CVE-k súlyossága és a javításukhoz szükséges idő között nincs releváns korreláció. Illetve, az általunk vizsgált minta alapján bizonyos nyelveknek (pl. C++) vannak erősen jellemző hibatípusai, míg másoknak nincsenek egyértelműen kiugró hibacsoportok.

Ezek az információk, a limitált adatmennyiségünk ellenére, hasznosak lehetnek projektmenedzsereknek, és fejlesztőknek egyaránt, hiszen informálhatják döntésüket azzal kapcsolatban, hogy melyek azok a potenciális hibaforrások, amelyekre a leginkább érdemes figyelmet fordítani, vagy megelőzésükre célzott szakképzéseket indítani. Felhasználhatóak továbbá különböző hiba előrejelzésekkel kapcsolat gépi tanulási feladatokhoz is.

A prezentált eredményeket egy nemzetközi konferencián is bemutattuk [1].

Irodalomjegyzék

[1] Gábor Antal, Balázs Mosolygó, Norbert Vándor, and Péter Hegedűs. A data-mining based study of security vulnerability types and their mitigation in different languages. In *International Conference on Computational Science and Its Applications*, pages 1019–1034. Springer, 2020.

[2] Thanapon Bhuddtham and Pirawat Watanapongse. Time-related vulnerability lookahead extension to the cve. In *2016 13th International Joint Conference on Computer Science and Software Engineering (JCSSE)*, pages 1–6. IEEE, 2016.

[3] Ying Dong, Wenbo Guo, Yueqi Chen, Xinyu Xing, Yuqing Zhang, and Gang Wang. Towards the detection of inconsistencies in public security vulnerability reports. In *28th {USENIX} Security Symposium ({USENIX} Security 19)*, pages 869–885, 2019.

[4] Stefan Frei, Martin May, Ulrich Fiedler, and Bernhard Plattner. Large-scale vulnerability analysis. In *Proceedings of the 2006 SIGCOMM Workshop on Large-Scale Attack Defense*, LSAD '06, page 131–138, New York, NY, USA, 2006. Association for Computing Machinery.

[5] Georgios Gousios. The ghtorrent dataset and tool suite. In *Proceedings of the 10th Working Conference on Mining Software Repositories*, MSR '13, pages 233–236, Piscataway, NJ, USA, 2013. IEEE Press.

[6] Andrew Kronser et al. Common vulnerabilities and exposures: Analyzing the development of computer security threats. 2020.

[7] D. Kuhn, Mohammad Raunak, and Raghu Kacker. An analysis of vulnerability trends, 2008-2016. pages 587–588, 07 2017.

[8] Frank Li and Vern Paxson. A large-scale empirical study of security patches. In *Proceedings of the 2017 ACM SIGSAC Conference on Computer and Communications Security*, pages 2201–2215, 2017.

[9] Xiang Li, Jinfu Chen, Zhechao Lin, Lin Zhang, Zibin Wang, Minmin Zhou, and Wanggen Xie. A mining approach to obtain the software vulnerability characteristics. In *2017 Fifth International Conference on Advanced Cloud and Big Data (CBD)*, pages 296–301. IEEE, 2017.

[10] Fabio Massacci and Viet Hung Nguyen. Which is the right source for vulnerability studies? an empirical analysis on mozilla firefox. In *Proceedings of the 6th International Workshop on Security Measurements and Metrics*, MetriSec '10, New York, NY, USA, 2010. Association for Computing Machinery.

[11] V. Mounika, X. Yuan, and K. Bandaru. Analyzing cve database using unsupervised topic modelling. In *2019 International Conference on Computational Science and Computational Intelligence (CSCI)*, pages 72–77, 2019.

[12] Syed Shariyar Murtaza, Wael Khreich, Abdelwahab Hamou-Lhadj, and Ayse Basar Bener. Mining trends and patterns of software vulnerabilities. *Journal of Systems and Software*, 117:218–228, 2016.

[13] Sarang Na, Taeeun Kim, and Hwankuk Kim. A study on the classification of common vulnerabilities and exposures using naïve bayes. In *International Conference on Broadband and Wireless Computing, Communication and Applications*, pages 657–662. Springer, 2016.

[14] Luis Gustavo Araujo Rodriguez, Julia Selvatici Trazzi, Victor Fossaluza, Rodrigo Campiolo, and Daniel Macêdo Batista. Analysis of vulnerability disclosure delays from the national vulnerability database. In *Anais do I Workshop de Segurança Cibernética em Dispositivos Conectados*. SBC, 2018.

[15] Jukka Ruohonen, Sami Hyrynsalmi, Sampsa Rauti, and Ville Leppänen. Mining social networks of open source cve coordination. In *Proceedings of the 27th Inter-*

national Workshop on Software Measurement and 12th International Conference on Software Process and Product Measurement, pages 176–188, 2017.

[16] Jukka Ruohonen, Sampsa Rauti, Sami Hyrynsalmi, and Ville Leppänen. A case study on software vulnerability coordination. *Information and Software Technology*, 103:239–257, 2018.

[17] Sagar Samtani, Shuo Yu, Hongyi Zhu, Mark Patton, John Matherly, and HsinChun Chen. Identifying supervisory control and data acquisition (scada) devices and their vulnerabilities on the internet of things (iot): a text mining approach. *IEEE Intelligent Systems*, 2018.

[18] Luis Alberto Benthin Sanguino and Rafael Uetz. Software vulnerability analysis using cpe and cve. *arXiv preprint arXiv:1705.05347*, 2017.

[19] Clemens Sauerwein, Christian Sillaber, Michael M Huber, Andrea Mussmann, and Ruth Breu. The tweet advantage: An empirical analysis of 0-day vulnerability information shared on twitter. In *IFIP International Conference on ICT Systems Security and Privacy Protection*, pages 201–215. Springer, 2018.

[20] M. Shahzad, M. Z. Shafiq, and A. X. Liu. A large scale exploratory analysis of software vulnerability life cycles. In *2012 34th International Conference on Software Engineering (ICSE)*, pages 771–781, 2012.

[21] Anshu Tripathi and Umesh Kumar Singh. Evaluation of severity index of vulnerability categories. *International Journal of Information and Computer Security*, 5(4):275–289, 2013.

[22] Leon Li Wu, Boyi Xie, Gail E Kaiser, and Rebecca Passonneau. Bugminer: Software reliability analysis via data mining of bug reports. 2011.

[23] Zhengzi Xu, Bihuan Chen, Mahinthan Chandramohan, Yang Liu, and Fu Song. Spain: security patch analysis for binaries towards understanding the pain and pills. In *2017 IEEE/ACM 39th International Conference on Software Engineering (ICSE)*, pages 462–472. IEEE, 2017.

[24] Yasuhiro Yamamoto, Daisuke Miyamoto, and Masaya Nakayama. Text-mining approach for estimating vulnerability score. In *2015 4th International Workshop on Building Analysis Datasets and Gathering Experience Returns for Security (BADGERS)*, pages 67–73. IEEE, 2015.

[25] Su Zhang, Doina Caragea, and Xinming Ou. An empirical study on using the national vulnerability database to predict software vulnerabilities. In *International conference on database and expert systems applications*, pages 217–231. Springer, 2011.

7. fejezet

Nyilatkozat

Alulírott Mosolygó Balázs József programtervező informatikus BSc szakos hallgató, kijelentem, hogy a dolgozatomat a Szegedi Tudományegyetem, Informatikai Intézet Szoftverfejlesztés Tanszékén készítettem, programtervező informatikus BSc diploma megszerzése érdekében.

Kijelentem, hogy a dolgozatot más szakon korábban nem védtem meg, saját munkám eredménye, és csak a hivatkozott forrásokat (szakirodalom, eszközök, stb.) használtam fel.

Tudomásul veszem, hogy szakdolgozatomat a Szegedi Tudományegyetem Informatikai Intézet könyvtárában, a helyben olvasható könyvek között helyezik el.

Köszönetnyilvánítás

Ez a szakdolgozat a SETIT projekt (2018-1.2.1-NKP-2018-00004)[1] keretében készült.

Szeretnék köszönetet mondani Antal Gábornak a technikai és szellemi támogatásért, amivel a projekt készítése során végig ellátott. Dr. Hegedűs Péternek, aki a dolgozat rendszerezésében, és szakmai értéknek emelésében rengeteget segített. Végül, de nem utolsó sorban Vándor Norbertnek, aki az eszközök és statisztikák létrehozásában velem együtt dolgozott.

[1] A 2018-1.2.1-NKP-2018-00004 számú projekt a Nemzeti Kutatási és Innovációs Alapból biztosított támogatással, a "Nemzeti Kiválósági Program: 2018-1.2.1-NKP" pályázati program finanszírozásában valósult meg.

A. függelék

Említett CWE-k definíciói

CWE-20 Improper Input Validation

A termék bemenetet vagy adatot kap, amit nem vagy helytelenül validál.

CWE-22 Improper Limitation of a Pathname to a Restricted Directory ('Path Traversal')

A szoftver egy elérési útvonalat vár, amiben nem semlegesíti kellően a különleges elemeket, így előfordulhat, hogy korlátozott hozzáférésű dokumentumokhoz enged hozzáférést.

CWE-77 Improper Neutralization of Special Elements used in a Command ('Command Injection')

A szoftver előkészít egy parancsot vagy egy részét, amihez külsőleg befolyásolt részleteket használ, de ezeket nem, vagy nem megfelelően semlegesíti, ennek hatására a továbbadott parancs módosulhat.

CWE-79 Improper Neutralization of Input During Web Page Generation ('Cross-site Scripting')

A szoftver nem, vagy nem megfelelően semlegesít felhasználó által befolyásolt bemeneteket, amik később más felhasználóknak lesznek kiszolgálva weboldalon.

CWE-89 Improper Neutralization of Special Elements used in an SQL Command ('SQL Injection')

A szoftver előkészít egy SQL parancsot vagy egy részét, amihez külsőleg befolyásolt részleteket használ, de ezeket nem, vagy nem megfelelően semlegesíti, ennek hatására a továbbadott SQL parancs módosulhat.

CWE-119 Improper Restriction of Operations within the Bounds of a Memory Buffer

A szoftver műveleteket hajt végre egy memória pufferben, de képes a korlátokon kívül is írni, olvasni.

CWE-125 Out-of-bounds Read

A szoftver adatokat olvas a használt puffer vége után, vagy kezdete előtt.

CWE-200 Exposure of Sensitive Information to an Unauthorized Actor

A termék bizalmas információhoz enged hozzáférést, nem jogosult felhasználóknak.

CWE-295 Improper Certificate Validation

A szoftver nem, vagy nem megfelelően validálja a tanúsítványt.

CWE-352 Cross-Site Request Forgery (CSRF)

A webalkalmazás nem ellenőrzi kellően, hogy egy helyes kérés valóban a felhasználótól származik-e.

CWE-400 Uncontrolled Resource Consumption

A szoftver nem korlátozza kellően a limitált erőforrások foglalását, és karban tartását, ami lehetővé teszi egy külső hatás számára, hogy befolyásolja a felhasznált nyersanyag mennyiséget, ami ezek elfogyásához vezethet.

CWE-416 Use After Free

A program már felszabadított memóriát használ.

CWE-502 Deserialization of Untrusted Data

Az alkalmazás deszerializál nem megbízható adatot anélkül, hogy ellenőrizné, hogy érvényes eredményhez vezet-e.