



# DASTURIY TA'MINOTNING ZAIFLIKLARINI ANIQLASHDA GRAF- NEYRON TAHLIL USULLARI: CPGG MODELI VA H-GAT ARXITEKTURASI

*Fazliddinova N.A.<sup>1</sup>, Onarkulov M.<sup>1</sup>*

*<sup>1</sup>Farg'ona davlat universiteti, Farg'ona, O'zbekiston  
nigorafazliddinova38@gmail.com*

---

Zamonaviy dasturiy tizimlarning murakkabligi ortib borishi bilan kibernetika sohasida zaifliklarni aniqlashning samarali matematik usullariga bo'lgan ehtiyoj keskin kuchaydi.  $V(L) = c \cdot L^a$  empirik qonuniyatiga ko'ra, kod hajmi ikki barobar oshganda zaifliklar soni ikkidan ko'proq baravar ortadi. An'anaviy statik tahlil usullari (leksik tahlil, CFG-asoslangan oqim tahlili) miqyoslanish muammolari va yuqori yolg'on ijobiy natijalar (false positive) bilan cheklangan. Mazkur tezisda dasturiy ta'minotning ko'p qatlamli graf-semantik tahlili va H-GAT neyro-graf arxitekturasiga asoslangan yangi yondashuv taqdim etiladi.

**Kompozitsion Dastur Grafi (CPGG).** Taklif etilgan model dasturiy kodni to'rt qatlamli ko'p qirrali multigraf sifatida ifodalaydi:

$$CPGG = (V, E_{AST} \cup E_{CFG} \cup E_{PDG} \cup E_{CG}, T)$$

Bu yerda  $V$  – dastur tugunlari to'plami (o'zgaruvchilar, operatorlar, funksiyalar);  $T: E \rightarrow \{AST\text{-child}, CFG\text{-succ}, DDG\text{-dep}, CG\text{-call}\}$  – qirra turlari funksiyasi. Teorema 2.1 isbotlaganidek, CPGG CWE-120 (bufer to'lib ketishi), CWE-89 (SQL inyeksiya), CWE-416 (use-after-free) va CWE-862 (avtorizatsiya yetishmasligi) zaifliklarini aniqlash uchun zaruriy va yetarli strukturaviy ma'lumotni o'z ichiga oladi.



**Ierarxik Graf Diqqat Tarmog'ı (H-GAT).** H-GAT CPGG ni ikki darajada qayta ishlaydi. L1 darajasida (lokal agregatsiya) har bir tugun uchun qirra turiga ko'ra differentsial diqqat hisoblanadi:

$$\alpha_{(r)ij} = \text{softmax}_j(\text{LeakyReLU}(a^r[W^r h_i \parallel W^r h_j]))$$

Bu yerda  $W^r$  va  $a^r$  – har bir qirra turi  $r$  uchun mustaqil o'qitiladigan parametrlar. L2 darajasida (global agregatsiya) funksiyalararo ma'lumot almashinuvi birlashtiriladi. Aniqlash uchun ikki sinfli klassifikator Focal Loss funksiyasi bilan o'qitiladi:

$$FL(p_t) = -(1 - p_t)\gamma \log(p_t), \quad \gamma = 2$$

**Eksperimental natijalar.** Model samaradorligi uchta mustaqil ma'lumotlar to'plamida baholandi. H-GAT ning eng kuchli raqobatchi ReVeal bilan qiyosiy natijalari quyida keltirilgan:

| Ma'lumotlar to'plami | Precision | Recall | F1 (ReVeal) | F1 (H-GAT) |
|----------------------|-----------|--------|-------------|------------|
| Big-Vul              | 0.903     | 0.881  | 0.832       | 0.891      |
| Devign               | 0.928     | 0.897  | 0.851       | 0.912      |
| SARD                 | 0.971     | 0.958  | 0.901       | 0.964      |

H-GAT modeli ReVeal dan Big-Vul da 7.1%, Devign da 6.8%, SARD da 6.9% yuqori F1 ko'rsatkichini qayd etdi. Natijalarning statistik ahamiyatliliigi Wilcoxon testi ( $p = 0.0031$ ) va bootstrap 95% ishonch intervallari bilan tasdiqlandi. Inference vaqti funksiya boshiga 2–8 ms bo'lib, CI/CD muhitlariga real vaqt integratsiyasi uchun amaliy.

**Xulosa.** Ishlab chiqilgan CPGG modeli va H-GAT arxitekturasi zaifliklarni aniqlashda qirra turiga ko'ra differentsial diqqat mexanizmi orqali an'anaviy GNN yondashuvlaridan statistik jihatdan sezilarli darajada yuqori aniqlik ta'minladi.



Taklif etilgan yondashuv «Raqamli O'zbekiston – 2030» strategiyasi doirasida milliy axborot tizimlari xavfsizlik auditi va CI/CD quvurlariga integratsiya uchun amaliy asoslangan.

### Adabiyotlar

1. Zhou Y. et al. Devign: Effective Vulnerability Identification by Learning Comprehensive Program Semantics via Graph Neural Networks // Advances in NeurIPS. – 2019. – Vol. 32. – P. 10197–10207.
2. Veličković P. et al. Graph Attention Networks // Proceedings of ICLR. – 2018. – 12 p.
3. Fan J. et al. A C/C++ Code Vulnerability Dataset with Code Changes and CVE Summaries // Proceedings of MSR. – 2020. – P. 508–512.
4. Chakraborty S. et al. Deep Learning Based Vulnerability Detection: Are We There Yet? // IEEE Transactions on Software Engineering. – 2022. – Vol. 48, No. 9. – P. 3280–3298.
5. Lin T.-Y. et al. Focal Loss for Dense Object Detection // Proceedings of ICCV. – 2017. – P. 2980–2988.