

O abordare Data Mining pentru detectarea accesului neautorizat la baza de date.

1. Introducere
2. Lucrări asemănătoare
3. Modelul de clasificare
4. Dependentele între date
 - 4.1 Terminologia dependenței de date
 - 4.2 Metodologia
 - 4.2.1 Faza descoperirii modelului secvențial
 - 4.2.2 Faza generării secvențelor setate de citire și scriere
 - 4.2.3 Faza de generare a regulilor de dependență a datelor
5. Algoritm
6. Analiza experimentală
7. Concluzii
- Bibliografie

1. Introducere

Deși multe abordări diferite sunt folosite pentru a proteja datele importante în mediul de astăzi, aceste metode de multe ori nu reușesc. O modalitate de a face datele mai puțin vulnerabile este de a implementa Intrusion Detection System (IDS) în sistemele informatice critice. În cazul în care un sistem informatic este compromis, o detectare timpurie este cheia pentru recuperarea datelor pierdute sau deteriorate, fără complexitate mare. În ultimii ani, cercetătorii au propus o varietate de abordări pentru creșterea eficienței de detectare a intruziunilor și precizie. Dar cele mai multe dintre aceste eforturi s-au concentrat pe detectarea intruziunilor la nivel de rețea sau la nivel de sistem de operare. Ele nu sunt capabile să detecteze exact ce date au fost mai exact corupte, care sunt pagubele și care tranzacții au realizat aceeași corupție de date. Fără aceste informații, evaluarea rapidă a daunelor și recuperarea în timp optim nu pot fi atinse.

În această lucrare, ne propunem un model pentru identificarea tranzacțiilor rău intenționate, care sunt orientate la coruperea datelor. Atunci când un atacator sau un utilizator rău intenționat actualizează baza de date, prejudiciul rezultat se poate răspândi foarte rapid în alte părți ale bazei de date prin intermediul utilizatorilor valabili. Detectarea rapidă și precisă a unui atac cibernetic pe un sistem de baze de date este o condiție prealabilă pentru evaluarea și recuperarea rapidă a gradului de distrugere. Tranzacțiile rău intenționate identificate în

această lucrare pot fi folosite mai târziu pentru evaluarea daunelor în baza de date și procedurile de recuperare.

Abordarea noastră se concentrează pe dependențele data mining printre elementele de date din baza de date. Prin dependență de date ne referim la corelații de acces la date între două sau mai multe elementele de date. Tehnicile prezentate utilizează abordarea de data mining pentru a genera dependențele de date între elementele de date. Aceste dependențe generate sunt sub formă de regulilor de clasificare, și anume, înainte ca un element de date să fie actualizat în baza de date, ce alte elemente trebuie să fie citite și după ce acest element de date este actualizat ce alte elemente sunt cele mai susceptibile de a fi actualizate de către aceeași tranzacție.

1. Lucrări asemănătoare

O intruziune este definită ca orice set de acțiuni care încearcă să compromită integritatea, securitatea sau disponibilitatea unei resurse.

Inteligența artificială și aplicații de date în exploatare de detectare a intruziunilor sunt angajați de către unii cercetători pentru a reduce efortul uman pentru construirea IDS și pentru a crește acuratețea de detectare.

De exemplu abordări data mining au fost realizate pentru a detecta comportamente frauduloase într-o rețea de telecomunicații de către Fawcett și Provost.

S-a realizat o cercetare destul de limitată în domeniul de detectare a intruziunilor în baze de date. De exemplu modelul Hidden Markov a fost propus să detecteze coruperea datelor în mod dăunător. Lee a utilizat semnăturile în timp pentru a descoperi accese nedorite la baza de date. Abordarea este de a eticheta semnătura timp la elementele de date. O alarmă de securitate este ridicată în momentul în care o tranzacție încearcă să scrie date temporale, date care au fost deja actualizate într-o perioadă de timp.

2. Modelul de clasificare

Ne propunem să folosim abordarea data mining pentru determinarea dependențelor de date în sistemul de baze de date. Regulile de clasificare care reflectă dependențele de date sunt deduse direct din log-ul de baza de date. Aceste norme reprezintă de fapt identificarea datelor care probabil ar trebui citite înainte de efectuarea unei operații de actualizare și care date ar trebui scrise după această operație de actualizare.

Tranzacții care nu sunt conforme cu dependențele de date generate sunt marcate ca operațiuni anormale.

Se poate observa de la aplicații de baze de date din lumea reală că, deși programul de tranzacționare se schimbă, adesea, structura întregii baze de date și corelațiile esențiale de date se schimbă foarte rar.

Modelul propus este conceput pentru a identifica tranzacțiile dăunătoare executate în SGBD de un intrus care a ocolit mecanismul de control al accesului al unui sistem de baze de date.

De exemplu, intrusul poate avea acces la o bază de date prin utilizarea atacului de injectare SQL la o porțiune a aplicației mai vulnerabilă sau de a fura parola unui utilizator legitim. Astfel, un intrus poate accesa baza de date de pe un site la distanță prin executarea tranzacțiilor manual sau printr-o altă aplicație.

O tranzacție este o unitate logică de prelucrare a bazei de date care include una sau mai multe operațiuni de access la baza de date. Modelul nostru prevede ca log-urile bazei de date să înregistreze atât operațiunile de citire cât și de scriere pentru fiecare tranzacție.

3. Dependențele între date

Dependența de date efectuează analiza de dependențele de date între elementele de date din baza de date. Următoarele definiții ajută la înțelegerea conceptului.

4.1 Terminologia dependenței de date

Deoarece scopul nostru general este de a descoperi dependențele de date care sunt legate de succesiune de operații efectuate de tranzacții, vom defini prima secvență în contextul nostru.

Definiția 1: O secvență este o lista ordonată de citire și / sau scriere de operațiuni. Vom indica o secvență s prin $\langle o_1(d_1), o_2(d_2), \dots, o_n(d_n) \rangle$, unde $o_i \in \{r, w\}$ și d_k este un element de date, $1 \leq k \leq n$. $D(s)$ reprezintă setul de elemente de date conținute în secvență, $D(s) = \{d_1, d_2, \dots, d_n\}$.

Sprijinul pentru o secvență este definit ca fracțiunea din totalul tranzacțiilor care conține această secvență.

Citirea și scrierea secvenței sunt folosite pentru a defini citirea și scrierea dependenței respective.

Definiția 2: Secvența Citește al elementului x este o secvență cu formatul $\langle r(d_1), r(d_2), \dots, r(d_n), w(x) \rangle$ care reprezintă faptul că tranzacția ar putea avea nevoie pentru ca să citească toate datele d_1, d_2, \dots, d_n în această ordine înainte de tranzacția să actualizeze elementele de date x . Trebuie să se noteze că fiecare element de date poate avea mai multe secvențe de citire de lungimi variabile. Toate aceste secvențe sunt numite împreună Citește Secvența Set al acelui element de date.

Notăția $rs(x)$ este folosită pentru a indica citirea secvenței de element de date x . De exemplu, luăm în considerare declarația următoare de actualizare într-o tranzacție.

Update set Tabelul 1 $x = a + b + c$ în cazul în care $d = 90$;

În această declarație, înainte de a actualiza x , valorile a, b, c și d trebuie să fie citite și apoi noua valoare a lui x se calculează. Deci, $\langle r(a), r(b), r(c), r(d), w(x) \rangle \in rs(x)$. Trebuie să se constate că jurnalul de baza de date conține imagini ale lui x numai înainte și după tranzacție, în loc de operația matematică utilizată pentru a calcula x , adică, $x = a + b + c$. Exemplul de mai sus este doar pentru a ilustra conceptul de secvență citită. Jurnal de date care conține tranzacția de mai sus poate arăta de fapt ca:

T1: $r(m), r(n), w(y), r(u), r(v), r(a), r(b), r(c), r(d), w(x), r(a), w(c), \text{commit}$.

Înainte de a scrie operația $w(x)$, 8 elemente de date au fost citite. Unele dintre ele nu pot avea dependențele de date cu x , de exemplu, ele sunt citite de către o altă declarație SQL în aceeași tranzacție.

Aceasta înseamnă că noua valoare a lui x nu este direct dependentă de valorile acestor 8 elemente de date. Scopul este de a arăta că pentru actualizarea lui x , elementele a, b, c și d trebuie mai mult ca sigur citiți și sunt relevanți pentru a calcula noua valoare a lui x . Trebuie să se noteze că rezultatul poate doar ilustra că a și b au dependențe de date cu x . Acest lucru se poate întâmpla atunci când unele tranzacții doar citesc valorile lui a și b înainte de actualizarea lui x .

Definiția 3: Secvența de scriere de elemente de date x este o secvență cu formatul $\langle w(x), w(d_1), w(d_2), \dots, w(d_n) \rangle$ care reprezintă faptul că tranzacția ar putea avea nevoie pentru a scrie toate datele d_1, d_2, \dots, d_n în această ordine după ce tranzacția actualizează elementele de date x . Trebuie să se constate că fiecare element de date poate avea mai multe

secvențe de scriere de lungimi diferite. Toate aceste secvențe sunt numite împreună Scrie Secvența Set al acelui element de date.

De exemplu considerăm următoarea declarație de actualizare într-o singură tranzacție:

Update Table1 set $x = a + b + c$ where ...

Update Table1 set $y = x + u$ where ...

Update Table1 set $z = x + w + v$ where ...

Folosind exemplul de mai sus, se poate nota că $\langle w(x), w(y), w(z) \rangle$ este o secvență de scriere a elementului de date x , $\langle w(x), w(y), w(z) \rangle \in ws(x)$, unde $ws(x)$ arată secvența set de scriere a lui x .

Definiția 4: Greutatea dependenței datelor indică în ce măsură un element de date x depinde de alte elemente de date, de exemplu, $D(s) - x$, în secvența de scriere sau citire s . Este definită de posibilitatea de citire (scriere), a acestor elemente de date înainte sau după actualizarea lui x . Noțiunile $rweight(x, D(s) - x)$ și $wweight(x, D(s) - x)$ denotă greutatea de dependenței de citire respectiv scriere. Un prag pre-set este utilizat pentru a identifica dacă o dependență este slabă sau puternică.

Figura 1 ilustrează un exemplu de dependență de date. Element de date x relații de dependență de citire cu $\{a, b, c, d\}$, $\{c, d\}$, și $\{x, e, f\}$. De asemenea are relații de dependență de scriere cu $\{y, z\}$ și $\{u, v\}$. Să presupunem că pragul predefinit de greutate de dependență de date este de 40%. Apoi, pentru dependența de citire doar $\{a, b, c, d\}$ are o dependență de date puternică cu x . În mod similar pentru dependența de scriere numai $\{u, v\}$ are o dependență de date puternică cu x .

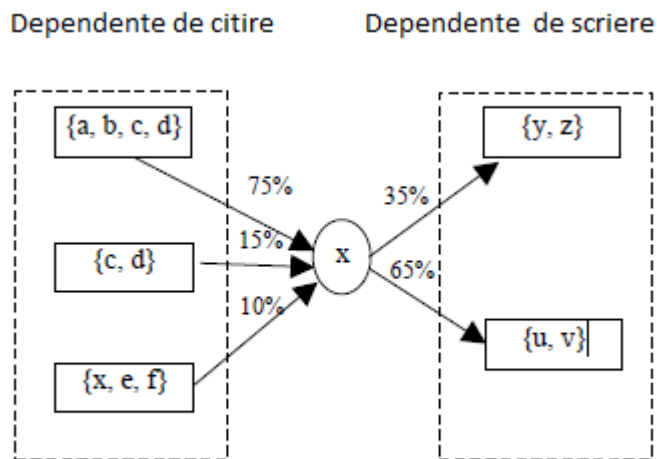


Figura 1. Exemplu de dependente de date

3.2 Metodologia

Pentru că metoda noastră utilizează secvențe de operații, de exemplu, ce succesiune de operații de citire trebuie să fie efectuate înainte de o operație de actualizare și ce succesiune de operații de scriere trebuie să se facă după aceeași operație de actualizare, este în mod intuitiv similar cu modelul secvențial.

Dar, doar prin utilizarea algoritmului modelului secvențial pe jurnalul sau logul bazei de date, putem obține câteva modele secvențiale consistente de operații mixte de citire și scriere și aceste modele secvențiale nu reflectă neapărat corelările de date esențiale în sistemul bazei de date. În plus, este dificil să se aplice direct aceste secvențe pentru detectarea tranzacțiilor rău intenționate. Prin analiza atentă problemele întâmpinate, am descoperit că printr-un algoritm de generare de reguli, algoritmul modelului secvențial poate fi utilizat să genereze clasificarea regulilor dorite pentru scopul propriu.

Problema descoperirii dependențelor de date este împărțită în trei pași: faza descoperirii modelului secvențial, faza generării secvențelor setate de citire și scriere și faza de generare a regulilor de dependență a datelor.

3.2.1 Faza descoperirii modelului secvențial

Se consideră 10 exemple de tranzacții ca în tabelul 1. $R(x)$ și $w(x)$ reprezintă operații de citire și scriere fără pierderea generalității, întregii sunt folosiți pentru a reprezenta fiecare element de date din bază. Cu un suport minim setat la 25%, de exemplu un suport minim de 3 tranzacții.

Tabel 1. Exemplu de tranzacții pentru modelul secvențial

trans. ID	Operațiile tranzacției
1	$r(7), r(1), r(6), w(5), r(1), w(4);$
2	$r(1), r(5), w(1), r(4), r(5), w(4);$
3	$r(7), r(6), r(2), w(4), r(7), r(3), w(6), r(1), r(6), w(2),$ $r(3), r(5), r(2), w(5);$
4	$r(2), w(2), r(4), r(7), w(3), r(6), w(5), r(1), w(4);$
5	$r(5), r(3), r(6), w(7);$
6	$r(6), r(1), w(3), r(1), w(6), r(2), r(7), r(4), w(2);$
7	$r(2), r(5), w(6);$
8	$r(4), w(6);$
9	$r(6), r(5), w(5), r(3), r(4), w(4), r(3), w(7);$
10	$r(5), r(6), w(5), r(5), w(4);$

Tabelul 2 ilustrează 13 modele secvențiale dorite care satisfac suportul impus. De exemplu, modelul secvențial $\langle r(6), w(5), w(4) \rangle$ este suportat de tranzacțiile 1, 4, 9 și 10. Un exemplu de secvență care nu satisface suportul minim este secvența $\langle r(2), w(2), r(7) \rangle$ care este suportată doar de tranzacția 4. Unele secvențe, de exemplu $\langle r(1) \rangle$ și $\langle r(7), r(6) \rangle$ nu sunt în setul de răspuns deoarece nu sunt maxime cu toate că au suport minim.

Pentru a descoperi modelul secvențial din log-urile bazei de date, putem folosi algoritmi de model secvențial: AprioriAll, PrefixSpan și GSP. În mediul de testare folosim AprioriALL pentru generarea modelului secvențial în această fază cu toate că performanța acestuia nu este la fel de bună ca PrefixSpan și GSP. Această fază preliminară oferă baza în descoperirea dependențelor datelor printre elementele de date.

Model secvențial cu suport>25%	Suport
r(3)	30%
w(6)	40%
r(1), w(4)	30%
r(2), w(2)	30%
r(2), r(7)	30%
r(4), w(4)	30%
r(5), w(4)	30%
r(5), w(5)	30%
r(6), r(5)	30%
r(6), w(5), w(4)	40%
r(7), r(6), r(1)	30%
r(7), r(6), w(4)	30%
r(7), r(6), w(5)	30%

Tabel 2. Modelul Secvențial

3.2.2 Faza generării setului de secvențe de citire și scriere

Observand modelul secvențial din tabelul 2, este clar că anumite modele pot fi folosite pentru descoperirea de dependențe între date în timp ce alte modele nu ar trebui luate în considerare.

În primul rând, unele modele secvențiale conțin doar o operație. De exemplu, modelul secvențial $\langle r(3) \rangle$ sau $\langle w(6) \rangle$ conțin operații doar asupra uneia dintre date, așa că nici o dependență de date nu poate fi generată și drept urmare nu ar trebui luate în considerare.

În al doilea rând unele modele secvențiale conțin doar operații de citire. Din moment ce suntem preocupați în special de modificări dăunătoare ale elementelor de date, realizate de tranzacțiile unui utilizator, vom acorda atenție doar tranzacțiilor care conțin operații de scriere. Astfel modelele care conțin doar operații de citire vor fi de asemenea neglijate.

Pentru toate celelalte modele secvențiale, următoarele proceduri sunt angajate pentru a genera seturile de secvențe de citire și scriere. Pentru fiecare operație de scriere $w(d_i)$ în modelul secvențial, adăugăm $\langle r(d_{i1}), r(d_{i2}), r(d_{i3}), \dots, r(d_{in}), w(d_i) \rangle$ la setul de secvențe de citire a datelor d_i unde $\{r(d_{i1}), r(d_{i2}), r(d_{i3}), \dots, r(d_{in})\}$ este setul tuturor operațiilor de citire înainte de $w(d_i)$. În mod similar, adăugăm $\langle w(d_i), w(d_{j1}), w(d_{j2}), w(d_{j3}), \dots, w(d_{jk}) \rangle$ la setul de secvențe de scriere a datelor d_i unde $\{w(d_{j1}), w(d_{j2}), w(d_{j3}), \dots, w(d_{jk})\}$ este setul tuturor operațiilor de scriere după $w(d_i)$.

Tabelul 3 ilustrează seturile de secvențe scriere și citire generate utilizând metoda de deasupra, din modelul secvențial din tabelul 2. De exemplu secvența $\langle r(6), w(4) \rangle$ denotă ca înainte ca elementul de date 4 să fie actualizat, elementul de date 6 ar trebui citit. În timp ce secvența $\langle r(7), r(6), w(4) \rangle$ reprezintă faptul că înainte ca elementul de date 4 să fie actualizat, elementele de date 7 și 6 ar trebui citite în secvență. Din aceste două secvențe, cea care reprezintă o dependență mai exactă poate fi determinată prin analiza $rweight(4, \{6\})$ și $rweight(4, \{7, 6\})$ și aceasta va fi ilustrată în următorul subcapitol. În setul de secvențe de scriere există doar un element $\langle w(5), w(4) \rangle$ care denotă că după ce elementul de date 5 este actualizat, elementul de date 4 ar trebui actualizat.

Tabel 3. Seturi de Secvente Citire si Scriere

Setul de Secvente Citire	Setul de Secvente Scriere
r(1), w(4)	w(5), w(4)
r(2), w(2)	
r(4), w(4)	
r(5), w(4)	
r(5), w(5)	
r(6), w(5)	
r(6), w(4)	
r(7), r(6), w(4)	
r(7), r(6), w(5)	

3.2.3 Faza de generare a regulilor de dependență a datelor

Regulile de dependență a datelor sunt categorizate ca reguli de citire și reguli de scriere. Următoarea procedură este utilizată pentru a genera reguli de dependență a datelor. Pentru toate modelele secvențiale $\langle r(di1), r(di2), \dots, r(din), w(di) \rangle$ în setul de reguli de citire, generează reguli de citire cu formatul $w(di) \rightarrow r(di1), r(di2), \dots, r(din)$. Dacă securitatea regulii este mai mare decât securitatea minimă, atunci este adăugată la setul de răspunsuri ale regulilor de citire care descrie ca înainte de a actualiza di , elementele de date $di1, di2, \dots, din$, trebuie citite din aceeași tranzacție.

Tabel 4. Reguli generate de dependenta de date
Regulile dependentelor de date | Siguranta

$w(2) \rightarrow r(2)$	100%
$w(5) \rightarrow r(6)$	100%
$w(4) \rightarrow r(6)$	83%
$w(5) \rightarrow w(4)$	80%

În mod similar pentru toate modelele secvențiale $w(di), w(dj1), w(dj2), \dots, w(djk)$ în setul de secvențe de scriere, generează reguli de scriere cu formatul $w(di) \rightarrow w(dj1), w(dj2), \dots, w(djk)$. Dacă securitatea regulii este mai mare decât securitatea minimă, atunci este adăugată la setul de răspunsuri ale regulilor de scriere care descrie ca după actualizarea di , elementele de date $dj1, dj2, \dots, djk$ trebuie actualizate de aceeași tranzacție.

De exemplu, atât $\langle r(6), w(4) \rangle$ cât și $\langle r(7), r(6), w(4) \rangle$ aparțin setului de secvențe ale elementului de date 4. Așa că două reguli de citire: A: $w(4) \rightarrow r(6)$ și B: $w(4) \rightarrow r(7), r(6)$ pot fi generate. Dar nu reflectă cât de puternică este corelarea datelor între elementul de date 4 și {6} sau între 4 și {7,6} cu toate că ambele satisfac suportul minim specificat. Presupunem că securitatea minimă este setată la 70%. Datorită securității regulii B este 50%, de exemplu $rweight(4, \{7, 6\}) = 50\%$, nu se găsește în setul de reguli. În timp ce securitatea regulii A este de 83%, $rweight(4, \{6\}) = 83\%$, este selectată. Regulile de scriere și citire generate din setul de secvențe în Tabelul 3 sunt ilustrate în tabelul 4.

Aceste reguli funcționează ca și reguli de clasificare pentru a identifica tranzacții rău intenționate la sistemul de baze de date.

După generarea regulilor de citire și scriere, acestea pot fi utilizate pentru a detecta tranzacții dăunătoare prin verificarea jurnalului sau a logurilor bazei de date. Tranzacțiile care au făcut modificări în bază fără a urma regulile de dependență a datelor sunt marcate ca tranzacții dăunătoare bazei.

Procedura este după cum urmează. Pentru toate tranzacțiile bazei de date care au operatii de scriere, verifică dacă fiecare operație urmează regulile de dependență a datelor, de

exemplu dacă această tranzacție a citit elementele de date corespunzătoare înainte de actualizare și dacă a scris elementele de date corespunzătoare după actualizarea respectivă.

Iată un exemplu mai clar de a ilustra procedura de detectare.

Presupunem că avem tranzacțiile T1: r(2), r(5), w(2), r(6), r(1), w(7), r(4), r(3), r(5), w(5). În T1, elementele 2, 7 și 5 sunt actualizate.

Pentru elementul 2 regula $w(2) \rightarrow r(2)$ este satisfăcută deoarece înainte ca elementul 2 să fie actualizat, însuși elementul 2 este citit de tranzacție.

Pentru elementul 7, deoarece nu există nici o dependență de date pentru acesta, nu este nevoie să îl verificăm.

Pentru elementul 5, regula $w(5) \rightarrow r(6)$ este satisfăcută dar regula $w(5) \rightarrow w(4)$ nu este deoarece după ce elementul 5 este actualizat nici un alt element de date nu mai este actualizat de aceeași tranzacție. Deci tranzacția T1 este identificată ca și tranzacție dăunătoare.

4. Algoritm

Algoritmul formal pentru determinarea regulilor de dependență a datelor este prezentat după cum urmează:

Algoritm:

1. Inițializarea setului de secvențe de citire $RS = \{ \}$ și setului de secvențe de scriere $WS = \{ \}$;
2. Inițializarea setului de reguli de citire $RR = \{ \}$ și setului de reguli de scriere $WR = \{ \}$;
3. Generarea modelului secvențial $X = \{ x_i \mid \text{suport}(x_i) > \text{suportul minim} \}$ prin utilizarea algoritmului modelului secvențial existent;
4. Pentru fiecare model secvențial x_i unde $|x_i| > 1$

Dacă există o operație de scriere în el

Pentru fiecare operație scrisă $w_i \in x_i$

Dacă $\langle r(d_{i1}), r(d_{i2}), r(d_{i3}), \dots, r(d_{in}), w(d_i) \rangle \notin RS$ și

$\langle r(d_{i1}), r(d_{i2}), r(d_{i3}), \dots, r(d_{in}) \rangle \neq \langle \emptyset \rangle$

adaugă $\langle r(d_{i1}), r(d_{i2}), r(d_{i3}), \dots, r(d_{in}), w(d_i) \rangle$

la RS unde $r(d_{i1}), r(d_{i2}), r(d_{i3}), \dots, r(d_{in})$

toate sunt operații de citire înainte de $w(d_i)$

Dacă $\langle w(d_i), w(d_{j1}), w(d_{j2}), w(d_{j3}), \dots, w(d_{jk}) \rangle \notin WS$ și

$\langle w_{j1}, w_{j2}, w_{j3}, \dots, w_{jk} \rangle \neq \langle \emptyset \rangle$

adaugă $\langle w(d_i), w(d_{j1}), w(d_{j2}), w(d_{j3}), \dots, w(d_{jk}) \rangle$

la WS unde $w(d_{j1}), w(d_{j2}), w(d_{j3}), \dots, w(d_{jk})$

toate sunt operații de scriere după w_i

5. Pentru fiecare secvență din RS

Dacă suportă $\langle r(d_{i1}), r(d_{i2}), r(d_{i3}), \dots, r(d_{in}), w(d_i) \rangle$

/suportă $\langle w_i(d_i) \rangle >$ securitatea minimă

adaugă $w(d_i) \rightarrow r(d_{i1}), r(d_{i2}), \dots, r(d_{in})$ la RR

Pentru fiecare secvență din WS

Dacă suportă $\langle w(d_i), w(d_{j1}), w(d_{j2}), \dots, w(d_{jk}) \rangle$

/suportă $\langle w_i(d_i) \rangle >$ securitate minimă

adaugă $w(d_i) \rightarrow w(d_{j1}), w(d_{j2}), \dots, w(d_{jk})$ la WR

Pasii 1 și 2 inițializează seturile de secvență citire/scriere și seturile de reguli citire/scriere.

Pasul 3 angajează algoritmul de modelare secvențială existent pentru a genera modele secvențiale care consistă într-o secvență de operații de citire sau scriere care satisfac suportul minim.

Pasul 4 generează seturile de secvențe citeste sau scrie din modelul secvențial. Modelul secvențial care nu conține nici o operație de scriere nu sunt luate în considerare în aceasta fază. Pentru fiecare operație de scriere în toate celelalte modele, secvența care constă în toate secvențele de citire înainte de aceste operații de scriere și această operație de scriere sunt adăugate în setul de secvențe de citire. În mod similar pentru secvența ce conține operațiile de scriere înșăși și celelalte operații de scriere după ce aceste operații de scriere sunt adăugate setului de secvență de scriere.

Pasul 5 generează reguli de scriere și citire de la seturile de secvențe de scriere și citire bazate pe securitate minimă. Toate regulile care satisfac securitatea minimă se găsesc în seturile de reguli de scriere sau citire ca ieșiri, rezultate ale algoritmului.

6. Analiza experimentală

Mai multe experimente au fost efectuate pentru testarea performanței metodei propuse.

Două log-uri de baze de date diferite au fost generate pentru testarea atât a ratei adevărate pozitive cât și a ratei fals pozitive ale modelului nostru. Primul log a constat din tranzacții de baza de date sintetice, care au fost tratate ca tranzacții dăunătoare. Aceste tranzacții dăunătoare au fost generate aleator bazat pe ipoteza că atacatorul ar putea să aibe cunoștințe de dependențele de date din baza de date. Al doilea log sau jurnal al bazei de date a constat în tranzacții normale ale unui utilizator.

Tabelul 5 ilustrează bază de stabilire a experimentului nostru. În scopul de a testa măsura în care abordarea noastră este sensibilă la dependențele de date, tranzacțiile rău intenționate și de user normal, au fost generate bazat pe parametrii patru și cinci din tabelul 5, de exemplu, numărul mediu de operațiuni de citire imediat înainte de operațiunea de scriere din tranzacții și numărul mediu de scriere în tranzacții. Apoi, prin varierea unui parametru la un moment dat, am evaluat modul în care sistemul de detectare a intruziunii a răspuns la schimbarea parametrilor de performanță și dacă au fost sensibili la această schimbare.

Tabel 5. Situația de referință a experimentului

Suport	Siguranța	# operații citite	# operații scrise	# tranzacții
.15	.75	2	2	2000

Figura 2 prezintă ratele adevărate pozitive în detectarea tranzacțiilor dăunătoare. Jurnalul de baze de date cu tranzacțiile dăunătoare a fost folosit pentru acest experiment. Figura 2 arată că ratele adevărate pozitive cresc constant atunci când rata de dependență de date este mai puternică printre elementele de date. Este de remarcat faptul că atunci când numărul mediu de operații de scriere variază de la 1 la 5, crește rata de adevărat pozitiv de la 41% la 91%. Întrucât, în cazul în care numărul mediu de operații de citire imediat înainte de o operație de scriere în tranzacții variază de la 1 la 5, rata adevărat pozitiv crește de la 65% la 86%. Comparând cele două grafice din figura 2, se observă că rata de detecție adevărat pozitiv este mult mai sensibilă la numărul mediu de scriere într-o tranzacție. Aceasta înseamnă că, în cazul în care există mai multe declarații actualizate în tranzacții, rata de detecție va crește rapid.





Figura 2. Rate adevarat pozitive in detectarea tranzactiilor daunatoare

Figura 3 ilustrează ratele fals pozitive la testele de tranzacții normale de utilizare. Jurnalul de baze de date cu tranzacții normale de utilizare a fost folosit în aceste cazuri. Este de observat că rata fals pozitiv poate fi la fel de scăzută ca 12,5% atunci când dependența de date nu este foarte puternică. Rata maximă de fals pozitiv este de 29% în cazul în care numărul mediu de operații de citire imediat înainte de o operație de scriere în tranzacții este de 5. Comparativ cu Figura 2, se observă că odată cu creșterea de dependență de date, creșterea ratei adevărat pozitiv este mult mai mare decât cea a ratei de fals pozitiv.

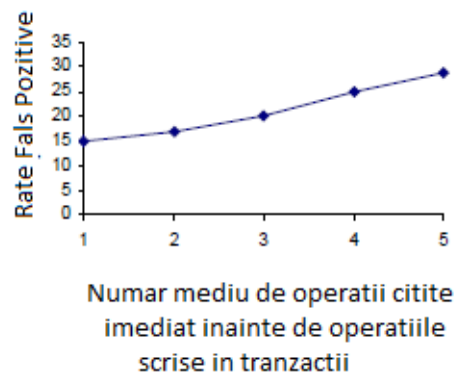
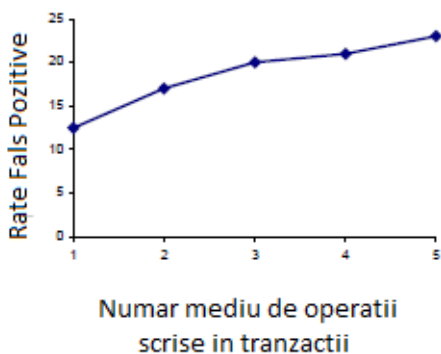


Figura 3. Ratele Fals Pozitive in Testarea tranzactiilor unui Utilizator Normal

7. Concluzii

În această lucrare am propus o abordare de data mining pentru a detecta tranzacțiile dăunătoare în sistemele de baze de date. Abordarea noastră se concentrează pe dependențe data mining printre elementele de date din baza de date. Regulile dependențelor de date

descoperite de dependentele de date miner sunt folosite ca regulile de clasificare pentru identificarea anomaliilor.

Experimentul pe tranzacțiile de baze de date sintetice ilustrează faptul că metoda propusă funcționează în mod eficient pentru a detecta tranzacțiile dăunătoare în sistemele de baze de date furnizând anumite dependențe de date existente.

Rezultatul arată în continuare că cu cât o dependență de date între elementele de date este mai puternică cu atât este mai mare performanța.

Bibliografie:

A Data Mining Approach for Database Intrusion Detection , Y. Hu, B. Panda, Computer Science and Computer Engineering Department, University of Arkansas.

(Text realizat de Beatrice Popa, grupa ABD master, ianuarie 2011, articol p711- hu, pentru cursul”Sisteme avansate de baze de date”).