ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΛΟΠΟΝΝΗΣΟΥ

ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΤΗΛΕΠΙΚΟΙΝΩΝΙΩΝ

Π.Μ.Σ ΕΠΙΣΤΗΜΗ ΚΑΙ ΤΕΧΝΟΛΟΓΙΑ ΥΠΟΛΟΓΙΣΤΩΝ

“Μελέτη Βάσεων Δεδομένων Γράφων και Πειραματική Αξιολόγηση”

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Μπαρέκα Μαρία

Επιβλέπων Καθηγητής: Βασιλάκης Κωνσταντίνος

05.2018, Τρίπολη

Περίληψη

Στη παρούσα διπλωματική εργασία εξετάζονται, οι βάσεις δεδομένων γράφων (GraphDataBases). Αρχικά, γίνεται μία σύντομη επισκόπηση των σχεσιακών βάσεων δεδομένων και κατόπιν παρουσιάζονται οι βάσεις δεδομένων NoSQL, αναπτύσσεται η τεχνολογία τους και πραγματοποιείται μια σύγκριση ανάμεσα τους.

Στη συνέχεια, η διπλωματική εργασία εστιάζει στη νέα γενιά βάσεων, τις βάσεις δεδομένων γράφων, παρουσιάζοντας τη δομή τους και τους λόγους επιλογής τους. Επιπρόσθετα, περιγράφονται ορισμένες από τις πιο διαδομένες βάσεις δεδομένων γράφων. Ακολουθεί η περιγραφή της Cayley, μιας βάσης δεδομένων τύπου γράφων, καθώς και της Gremlin, μιας γλώσσας ερωτημάτων η οποία χρησιμοποιείται από την Cayley. Τέλος, υπάρχει ένα σενάριο χρήσης εφαρμογής της Cayley στην οποία γίνεται χρήση της γλώσσας ερωτημάτων Gremlin.

Abstract

This thesis examines the technology of graph databases. Initially a brief overview of relational databases is given, and subsequently the NoSQL database branch is presented, their technology is detailed and a comparison is given.

Afterwards, this thesis focuses on the new generation of databases, i.e. graph databases, presenting their structure and their benefits. Furthermore, a number of the most widespread databases are described in more detail. This is followed by a detailed presentation of Cayley, which is a graph database, and Gremlin, a query language used by Cayley. Finally, a usage scenario for Cayley, including the use of the Gremlin language, is presented.

Περιεχόμενα

Κατάλογος Εικόνων

Κατάλογος Πινάκων

1

1. Εισαγωγή

Οι Βάσεις Δεδομένων και τα συστήματα διαχείρισής τους αποτελούν εδώ και αρκετές δεκαετίες αναπόσπαστο κομμάτι των συστημάτων λογισμικού αφού αποθηκεύουν και διαχειρίζονται τις πληροφορίες, οι οποίες με τη σειρά τους είναι το συνηθέστατα πλέον σημαντικό συστατικό των πληροφοριακών συστημάτων. Ο κύριος λόγος που τα συστήματα διαχείρισης βάσεων έχουν αποκτήσεις τεράστια ανάπτυξη είναι διότι τόσο ο προγραμματιστές όσο και οι επιχειρήσεις ικανοποιούν τις απαιτήσεις τους για διαχείριση δεδομένων μέσα από αυτές.

Όλα αυτά τα χρόνια έχουν αναπτυχθεί αρκετά αξιόλογα λογισμικά συστημάτων διαχείρισης βάσεων δεδομένων, τα οποία είτε είναι ανοιχτού κώδικα είτε κλειστού κώδικα. Μερικά παραδείγματα συστημάτων βάσεων δεδομένων είναι το MariaDB, η οποία ανήκει στα ΣΔΒΔ ανοιχτού κώδικα αλλά και το MicrosoftSQL Server το οποίο είναι ένα ΣΔΒΔ κλειστού κώδικα.

Όπως, αναφέρθηκε και προηγουμένως οι Σχεσιακές Βάσεις Δεδομένων (ΣΒΔ) χρησιμοποιούνται εδώ και αρκετές δεκαετίες από προγραμματιστές, ωστόσο οι μεγάλες υπολογιστικές και αποθηκευτικές απαιτήσεις των σημερινών εφαρμογών έχουν ωθήσει τις Βάσεις Δεδομένων στα όρια τους. Παράλληλα, η φύση των δεδομένων που χρησιμοποιούνται σε πολλές νέες κατηγορίες εφαρμογών, όπως οι εφαρμογές σημασιολογικού ιστού ή οι εφαρμογές ανάκτησης πληροφορίας, θέτουν νέες απαιτήσεις για τη διαχείριση των δεδομένων που δεν ικανοποιούνται με βέλτιστο τρόπο από τις κυρίαρχες τεχνολογίες βάσεων δεδομένων, δηλ. τις σχεσιακές βάσεις δεδομένων.

Γι’ αυτό το λόγο, τα τελευταία χρόνια έχουν εμφανιστεί νέες αρχιτεκτονικές Βάσεων Δεδομένων, οι οποίες επιχειρούν να καλύψουν τις νέες ανάγκες. Οι αρχιτεκτονικές αυτές έχουν τη γενική ονομασία «NOSQL» (τα αρχικά της οποίας σημαίνουν NotOnlySQL), και μερικές από τις “εταιρίες που τις χρησιμοποιούν είναι η Google,η Amazon αλλά και το Facebook.

Το σχεσιακό μοντέλο δυσκολεύεται αρκετά να υποστηρίξει τις σημερινές σύγχρονες εφαρμογές οι οποίες έχουν μεγάλες απαιτήσεις, αφού υπάρχουν αρκετοί περιορισμοί τόσο στην εσωτερική δομή της βάσης όσο και στους μηχανισμούς με

τους οποίες οι εφαρμογές αποκτούν πρόσβαση στα δεδομένα. Τα δυο πιο σημαντικά μειονεκτήματα που εμφανίζουν οι Βάσεις Δεδομένων:

1. Η δημιουργία και η διατήρηση του συστήματος της βάσης δεδομένων είναι μια διαδικασία ιδιαίτερα ακριβή.
2. Η κλιμάκωση τους είναι κακή.

Ακόμα, στα μειονεκτήματα των βάσεων δεδομένων θα προστεθεί το γεγονός ότι η ποσότητα και ο τύπος των δεδομένων, καθώς και το μέγεθός δηλώνονται κατά την αρχική σχεδίαση της βάσης δεδομένων. Ενώ, και η δομή των πινάκων των βάσεων δεδομένων είναι αρκετά περιοριστική για τα αντικείμενα του πραγματικού κόσμου που είναι πολύπλοκα.

Η δομή των πινάκων των βάσεων δεδομένων αποτελείται από γραμμές και στήλες, ενώ η διαίρεση των δεδομένων δημιουργεί αρκετούς πίνακες, οι οποίοι απαιτείται να συνδέονται μεταξύ τους γεγονός που οδηγεί σε μια αρκετά χρονοβόρα διαδικασία αποτίμησης ερωτήσεων αλλά και σχεδιασμού. Επομένως, η δομή των πινάκων μπορεί να χαρακτηριστεί περιοριστική για τα δεδομένα του πραγματικού κόσμου, τα οποία είναι περίπλοκα. Παράλληλα, για οποιαδήποτε αλλαγή ζητηθεί στη βάση δεδομένων απαιτείται παρέμβαση του διαχειριστή για την κατάλληλη διαμόρφωση του σχήματος της βάσης δεδομένων και τη βελτιστοποίηση της λειτουργίας της.

Όλα αυτά τα προβλήματα έχουν οδηγήσει στην μελέτη νέων συστημάτων διαχείρισης τα οποία να είναι ικανά να διαχειρίζονται αποτελεσματικά και αποδοτικά τα σύγχρονα δεδομένα. Ως απάντηση, στα μειονεκτήματα των βάσεων δεδομένων έρχεται η σχετικά καινούργια προσέγγιση της NoSql. Τα NoSql συστήματα μπορούν να χαρακτηριστούν εύκολα στη χρήση και την κατανόηση, προσαρμοστικά, ανθεκτικά, αποδοτικά, ενώ διαθέτουν υψηλή διαθεσιμότητα και επιτρέπουν την παράλληλη επεξεργασία ερωτημάτων. Αξίζει να σημειωθεί ότι οι πιο μεγάλοι δικτυακοί τόποι όπως είναι οι Google, το twitter, η Amazon, το Linkendin, κ.τ.λ. έχουν επικεντρωθεί στην τεχνολογία συστημάτων NoSql, απομακρυνόμενοι σταδιακά από τη χρήση των σχεσιακών βάσεων.

2. Βιβλιογραφική Ανασκόπηση

Σε αυτήν την ενότητα, θα παρουσιαστούν τόσο η τεχνολογία των Σχεσιακών Βάσεων Δεδομένων, οι οποίες χρησιμοποιούνται εδώ και αρκετές δεκαετίες, όσο και των βάσεων δεδομένων NoSql, για τις οποίες παρατηρείται έντονο ενδιαφέρον κατά το τελευταίο διάστημα. επίσης, θα πραγματοποιηθεί συγκριτική αξιολόγηση ανάμεσα στις δύο κατηγορίες βάσεων δεδομένων.

2.1 Βάσεις Δεδομένων και απαραίτητα χαρακτηριστικά

Με τον όρο *Βάση Δεδομένων* εννοείται ένα σύνολο πληροφοριών, οι οποίες τυπικά οργανώνονται σε ομάδες, με κάθε ομάδα να αντιστοιχεί σε αντικείμενα του πραγματικού κόσμου. Οι ομάδες είναι οργανωμένες με τέτοιο τρόπο ώστε να υπάρχουν λογικές σχέσεις μεταξύ τους. Οι λογικές σχέσεις επίσης αντιστοιχούν σε σχέσεις μεταξύ των ομάδων που υπάρχουν στον πραγματικό κόσμο. Συνολικά, μία βάση δεδομένων έχει σχεδιαστεί και υλοποιηθεί με σκοπό να χρησιμοποιηθεί για κάποιο σκοπό και να παρέχει συγκεκριμένες λύσεις σε έναν μικρόκοσμο.

Βασικό χαρακτηριστικό των βάσεων δεδομένων είναι ότι παρέχουν ένα κοινό τρόπο διαχείρισης των δεδομένων, προσφέροντας τη δυνατότητα εφαρμογής των βασικών λειτουργιών της πάνω στα αποθηκευμένα δεδομένα, τα οποία μπορεί να αλλάζουν συνεχώς. Επομένως, η βάση δεδομένων είναι ένα δυναμικό σύστημα αποθήκευσης και διαχείρισης δεδομένων και περιγράφει κάθε φορά την κατάσταση του μικρόκοσμου στον οποίο αναφέρεται και τον οποίο εξυπηρετεί.

2.2Ιδιότητες ACID

Οι βάσεις δεδομένων, για να προστατέψουν την ακεραιότητα των δεδομένων, χρησιμοποιούν την έννοια των δοσοληψιών. Ουσιαστικά, οι δοσοληψίες είναι μια ενότητα εκτέλεσης ενός προγράμματος που προσπελαύνει και ενημερώνει διάφορα δεδομένα. Για να διασφαλιστεί η αξιοπιστία της δοσοληψίας, υφίσταται ένα σύνολο ιδιοτήτων με το ακρωνύμιο ACID (Atomicity, Consistency, Isolation, Durability) – ατομικότητα, συνέπεια, απομόνωση και μονιμότητα. Οι ιδιότητες αυτές περιγράφονται στη συνέχεια.

- **Atomicity *(Ατομικότητα):*** Η ιδιότητα της ατομικότητας υποδεικνύει ότι είτε όλες οι πράξεις της δοσοληψίας καταχωρούνται στη βάση δεδομένων, είτε δεν καταχωρείται καμία. Επομένως, η ιδιότητα της ατομικότητας συμβάλλει στη διατήρηση της συνέπειας της βάσης δεδομένων, αφού αν αποτύχει ένα μέρος της δοσοληψίας τότε θα αποτύχει ολόκληρη η δοσοληψία και η βάση θα επιστρέψει στην αρχική της κατάσταση.
- **Consistency (Συνέπεια):** Η ιδιότητα της συνέπειας διασφαλίζει ότι η Βάση Δεδομένων διατηρείται σε μια συνεπή κατάσταση, συγκεκριμένα υποδεικνύοντας ότι κάθε δοσοληψία θα οδηγεί την βάση δεδομένων από τη μια συνεπή κατάσταση στην άλλη. Σε περίπτωση που μια δοσοληψία παραβιάζει κάποιο κανόνα της συνέπειας, ανακαλείται προκειμένου η ΒΔ να έχει μόνο έγκυρα δεδομένα. Ωστόσο επιτρέπεται κατά τη διάρκεια εκτέλεσης της δοσοληψίας να διέρχεται προσωρινά η βάση δεδομένων από μη συνεπείς καταστάσεις, καθώς ο έλεγχος για την τήρηση των κανόνων συνέπειας μπορεί να επιλεγεί να πραγματοποιείται κατά την επικύρωση της δοσοληψίας.
- **Isolation (Απομόνωση):** Η Απομόνωση δίνει τη δυνατότητα στη δοσοληψία να αγνοεί τις υπόλοιπες ταυτόχρονες συναλλαγές, υπό την έννοια ότι η κάθε δοσοληψία δεν επηρεάζεται από τις προσωρινές, μη συνεπείς καταστάσεις που οι άλλες δοσοληψίες δημιουργούν. Το χαρακτηριστικό της συγκεκριμένης ιδιότητας προσφέρει τη δυνατότητα τα δεδομένα της κάθε συναλλαγής να είναι διαθέσιμα μετά την ολοκλήρωση της συναλλαγής, ενώ μια δοσοληψία δεν γνωρίζει για τις υπόλοιπες δοσοληψίες οι οποίες πραγματοποιούνται παράλληλα, ούτε να εκτελεί η ίδια κάποιες ενέργειες για την αποτροπή της αλληλοπαρεμβολής, μια και αυτή διασφαλίζεται από το σύστημα διαχείρισης βάσεων δεδομένων.
- **Durability (Μονιμότητα):** Η ιδιότητα της Μονιμότητας παρέχει τα εχέγγυα πως όταν η δοσοληψία ολοκληρωθεί επιτυχώς, οι αλλαγές που έχει κάνει στη βάση δεδομένων υπάρχουν, ακόμα και αν προκύψουν αποτυχίες του συστήματος, όπως είναι για παράδειγμα η απώλεια ρεύματος.

Εικόνα 1:ΙδιότητεςACID

2.3 Θεώρημα CAP

Οι σημερινές εφαρμογές εκτελούνται σε πολλούς διακομιστές οι οποίοι είναι κατανεμημένοι σε γεωγραφικές περιοχές, με αυτό τον τρόπο υπάρχει ισορροπημένη κυκλοφορία του δικτύου σε ένα σύνολο διακομιστών, ακόμα και όταν σε κάποια τοποθεσία κάποιος διακομιστής τεθεί εκτός λειτουργίας. Σε αυτές τις περιπτώσεις, η κίνηση των δεδομένων ανακατευθύνεται στους διακομιστές οι οποίοι παραμένουν σε λειτουργία.

Ένα σύνολο ηλεκτρονικών υπολογιστών οι οποίοι συνεργάζονται αποκαλείται κατανεμημένο σύστημα. Ένα κατανεμημένο σύστημα δημιουργείται για να αυξηθεί η αποθηκευτική και υπολογιστική ικανότητα, προκείμενου να λυθούν προβλήματα τα οποία από μόνος του ένα υπολογιστής δεν είναι σε θέση να καταφέρει. Στην περίπτωση των εφαρμογών, ένα κατανεμημένο σύστημα θέτει δυο στόχους:

1. Να παρέχει στον χρήστη συνεχή, χωρίς προβλήματα λειτουργία, διασφαλίζοντας την απρόσκοπτη πρόσβασή του σε υπηρεσίες όπως είναι για παράδειγμα η χρήση του Facebook. Αυτό επιτυγχάνεται μέσω της ύπαρξης πολλών υπολογιστών, οι οποίοι συνεργάζονται για την αδιάλειπτη λειτουργία της εφαρμογής.
2. Να επεξεργάζονται τα δεδομένα τα οποία προκύπτουν από την εφαρμογή.

Τα οφέλη των κατανεμημένων συστημάτων είναι πολλά, αφού παρέχουν μεγαλύτερη υπολογιστική ισχύ και αποθηκευτικό χώρο προκείμενου να εξυπηρετούν τα δισεκατομμύρια αιτημάτων τα οποία προκύπτουν καθημερινά. Ωστόσο, η δημιουργία ενός συστήματος το οποίο συνδέεται με πολλούς υπολογιστές δεν είναι εύκολο εγχείρημα αφού προκύπτουν πολλές προκλήσεις.

Επομένως, λόγο της ύπαρξης ένας αρκετά πολύπλοκου κατανεμημένου συστήματος αποθήκευσης πληροφοριών αναπτύχθηκε το Θεώρημα CAP

(Consistency, Availability, Partitiontolerance – Συνεπεία, Διαθεσιμότητα, Ανοχή διαμερισμού), γνωστό και ως θεώρημαBrewer, οπού σύμφωνα με αυτό το θεώρημα είναι αδύνατο ένα κατανεμημένο σύστημα να παρέχει εγγυήσεις για την ταυτόχρονη παροχή των τριών βασικών ιδιοτήτων, αλλά έχει τη δυνατότητα να υποστηρίζει μόνο δύο από τρεις βασικές ιδιότητες:

- **Συνέπεια *(consistency):***η ιδιότητα αυτή αναπτύχθηκε και παραπάνω στις ιδιότητες ACID αλλά σύμφωνα με τον Brewer η κεντρική ιδέα είναι ότι όλοι οι κόμβοι μπορούν να βλέπουν τα ίδια δεδομένα την ίδια στιγμή, ακόμα και όταν τα δεδομένα της βάσης ενημερώνονται.
- **Διαθεσιμότητα *(availability):***προϋποθέτει ότι το σύστημα αποκρίνεται σε κάθε αίτημα με μια απάντηση για να ενημερώσει για την επιτυχία του ή τυχόν επιτυχία, καθώς και τα δεδομένα που αποτελούν την απάντηση στο αίτημα, εφ' όσον υπάρχουν.
- **Ανοχή διαμερισμού *(partitiontolerance):*** εγγυάται τη λειτουργία του συστήματος στην περίπτωση που ένα μέρος του συστήματος τεθεί εκτός λειτουργίας λόγω βλάβης στο δίκτυο, η οποία διαμερίζει τους κόμβους σε δύο ή περισσότερα υποσύνολα, όπου οι κόμβοι του κάθε υποσυνόλου μπορούν να επικοινωνήσουν μεταξύ τους αλλά όχι με τους κόμβους άλλων υποσυνόλων.Σε αυτή την περίπτωση το σύστημα πρέπει να είναι σε θέση και να αποκρίνεται στα μηνύματα που δέχεται.

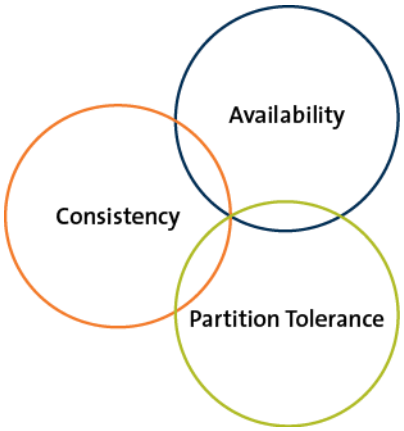

Εικόνα 2 Θεώρημα CAP

Με βάση το θεώρημα CAP, υπάρχουν τρεις διαφορετικοί συνδυασμοί ζευγών βασικών ιδιοτήτων που μπορούν να υποστηρίζονται, όπως φαίνεται στο σχήμα που ακολουθεί.

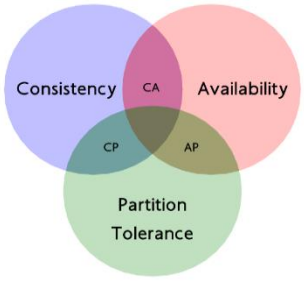

Εικόνα 3–Συνδυασμοί υποστηριζόμενων ιδιοτήτων βάσει του θεωρήματοςCAP

CA: Ο συνδυασμός αυτός εγγυάται υψηλή διαθεσιμότητα και συνέπεια ωστόσο δεν εγγυάται ανοχή στον διαμερισμό, είναι γνωστός και ως *συνδυασμός υψηλής διαθεσιμότητας*. Σε αυτόν συνδυασμό οι ενημερώσεις διαχέονται σταδιακά από τον έναν κόμβο στους υπόλοιπους, γεγονός που οδηγεί τα δεδομένα σε συνεπή κατάσταση αφού εμφανίζονται τα πιο ενημερωμένα.

CP: Ο συνδυασμός αυτός παρέχει συνεπεία και αντοχή στον διαμερισμό αλλά δεν εγγυάται διαθεσιμότητα, είναι γνωστός και ως *συνδυασμός ισχυρής συνέπειας*. Το βασικό του πρόβλημα είναι ότι δεν παρέχει συνεχή πρόσβαση στα δεδομένα σε περίπτωση βλάβης

AP: Ο συνδυασμός αυτός εγγυάται διαθεσιμότητα και ανοχή στον διαμερισμό, αφού παρέχει συνεχή πρόσβαση στα δεδομένα ωστόσο υπάρχει περίπτωση να μην έχει γίνει ενημέρωση στα δεδομένα. Τα δεδομένα *τελικώς* θα ενημερωθούν, αλλά μπορεί να είναι ορατές μη συνεπείς μορφές τους, και γι' αυτό ο συνδυασμός ονομάζεται *συνδυασμός ενδεχόμενης συνέπειας (eventual consistency).*

2.4 Σχεσιακά Συστήματα Βάσεων Δεδομένων

Παράλληλα με την πρόοδο της θεωρίας των σχεσιακών βάσεων δεδομένων αναπτύχθηκαν τα Σχεσιακά Συστήματα Διαχείρισης Βάσεων Δεδομένων *(ΣΣΔΒΔ, Relational Database Management Systems – RDBMS),* δηλαδή συγκεκριμένα συστήματα που υλοποιούν και καθιστούν διαθέσιμες σχεσιακές βάσεις δεδομένων.

Παραδείγματα σχεσιακών συστημάτων βάσεων δεδομένων είναι η Oracle, ο SQLserverκαι η MySQL.

Στο σχεσιακό μοντέλο, η βάση δεδομένων αποτελείται από στοιχεία που ονομάζονται *πίνακες* και υφίσταται σχέσεις μεταξύ αυτών. Οι πίνακες, με την σειρά τους, περιέχουν εγγραφές (records), οι οποίες στο σχεσιακό μοντέλο αντιστοιχούν στις γραμμές του κάθε πίνακα οπού η σειρά εμφάνισης τους δεν έχει απολύτως καμία σημασία.

Για κάθε πίνακα, είναι απαραίτητο κάθε γραμμή (εγγραφή) να μπορεί να οριστεί μοναδικά για αυτό το λόγο χρησιμοποιείται το *πρωτεύον κλειδί*. Το πρωτεύον κλειδί αποτελείται από ένα ή περισσότερα πεδία του πίνακα, όπου κάθε συνδυασμός τιμών τους υπάρχει το πολύ μια φορά στις γραμμές του πίνακα. Υφίσταται επίσης η έννοια του *ξένου κλειδιού*, η οποία προσδιορίζει τον τρόπο με τον οποίο συνδέονται οι πίνακες μεταξύ τους μέσω των σχέσεων. Ουσιαστικά, ο συνδυασμός τιμών των στηλών που ανήκουν σε ένα ξένο κλειδί σε έναν πίνακα, πρέπει να εντοπίζεται σε αντίστοιχες στήλες ενός άλλου πίνακα.

2.5 NoSql

Η προσέγγιση NoSQL, το όνομα της οποίας είναι συντομογραφία της φράσης “NotOnlySQL”, ερευνάται από τους προγραμματιστές σαν απάντηση στις νέες απαιτήσεις που έχουν αναπτυχθεί. Η πρώτη παρουσίαση των βάσεων NoSQLπραγματοποιήθηκε το 2009, εμφανίζοντας έναν νέο τρόπο με τον οποίο μπορούν οι πληροφορίες του διαδικτύου να αποθηκευτούν.

Ακόμα, δεν υπάρχει ένας ακριβής ορισμός για το τι περιλαμβάνει ένα σύστημα NoSQL, ωστόσο μπορεί να θεωρηθεί σαν μια ομάδα συστημάτων βάσεων δεδομένων οι οποίες αναπτύσσονται με σκοπό τον αποδοτικό χειρισμό μεγάλων ποσοτήτων πληροφορίας χρησιμοποιώντας έναν διαφορετικό τρόπο από τον κλασσικό που είναι ο σχεσιακός τρόπος αποθήκευσης σε συνδυασμό με τη γλώσσα SQL. Υπάρχουν εταιρίες και οργανισμοί οι οποίοι πραγματοποιούν ευρεία χρήση αυτής της τεχνολογίας προκειμένου να αντεπεξέλθουν στις τεράστιες ποσότητες δεδομένων οι οποίες παράγονται από τους χρήστες τους. Μερικές από τις εταιρίες αυτές είναι η Amazon, το Facebook και η Google.

Τα συστήματα NoSQL είναι σχεδιασμένα έτσι ώστε να αποθηκεύουν μεγάλες ποσότητες δεδομένων ενώ παράλληλα είναι ικανά να επεξεργάζονται τα δεδομένα τα οποία κατανεμημένα σε μεγάλο αριθμό servers. Οι Βάσεις Δεδομένων NoSQL αποτελούνται από αδόμητη ή ημιδομήμενη αναπαράσταση δεδομένων, πράγμα το οποίο σημαίνει ότι η δομή καθορίζεται ανάλογα με τις ανάγκες που προκύπτουν, όπως για παράδειγμα η προσθήκη ενός νέου πεδίου μόνο στις εγγραφές που κρίνεται απαραίτητο.

Το μεγάλο πλεονέκτημα των συστημάτων NoSQL είναι η προσαρμοστικότητα που διαθέτουν και αυτός είναι και ένας βασικός λόγος που υιοθετήθηκαν από μεγάλες εταιρίες του χώρου του διαδικτύου στον χειρισμό δεδομένων μεγάλου όγκου, αφού τόσο αποθηκεύουν όσο και ανακτούν μεγάλες ποσότητες δεδομένων χωρίς να επηρεάζονται από τις σχέσεις που υφίστανται μεταξύ αυτών των στοιχειών.

Επιπλέον, οι βάσεις δεδομένων τύπου NoSQL έχουν σκοπό να καλύψουν τις ανάγκες του μεγάλου αριθμού χρηστών των εφαρμογών Internet, πετυχαίνοντας ταχύτατους χρόνους απόκρισης κάτι το όποιο κάνει την εμπειρία χρήσης των εφαρμογών αυτών περισσότερο πετυχημένη.

2.5.1 Τεχνολογίες NoSql

Οι βάσεις δεδομένων NoSQLκατηγοριοποιούνται ανάλογα με τον τρόπο αποθήκευσης δεδομένων. Στη συνέχεια θα περιγράψουμε διάφορους τύπους αποθήκευσης, οι οποίοι είναι:Column-oriented, Key-valuesStores, Document-basedstores και GraphDB.

2.5.1.1 Column-oriented (Στηλοκεντρικές Βάσεις Δεδομένων)

Αυτή η τεχνολογία αποθηκεύει τα δεδομένα σε στήλες, αντίθετα με τις σχεσιακές βάσεις δεδομένων οι οποίες αποθηκεύουν τα δεδομένα σε γραμμές. Στις στηλοκεντρικές βάσεις οι εγγραφές αποθηκεύονται, ανακτώνται και υπόκεινται σε επεξεργασία στηλοκεντρικά, όπως αναφέρει και το όνομα τους, ενώ υπάρχει δυνατότητα να περιέχουν τεράστιο αριθμό στηλών. Χαρακτηριστικό παράδειγμα είναι το Cassandra το οποίο δημιουργήθηκε από το Facebook.

Για παράδειγμα, σε ένα σχεσιακό σύστημα διαχείρισης βάσεων δεδομένων παρουσιάζει τα δεδομένα που αντιπροσωπεύει ένα δισδιάστατο πίνακα, στηλών και γραμμών, δηλαδή μια βάση δεδομένων μπορεί να έχει έναν πίνακα με την παρακάτω μορφή.

ROWLD	EMP_ID	LASTNAME	FIRSTNAME	SALARY
001	**10**	**Smith**	**Joe**	**40.000**
002	**11**	**Jones**	**Mary**	**50.000**
003	**12**	**Johnson**	**Cathy**	**44.000**
004	**13**	**Jones**	**Bob**	**55.000**

Πίνακας 1–Μοντέλο δεδομένων σε μία σχεσιακή βάση δεδομένων

Σε μια σχεσιακή βάση τα δεδομένα θα αποθηκεύονταν εσωτερικά όπως φαίνεται στον Πίνακα 2.

```
001:10,Smith,Joe,40000;

002:11,Jones,Mary,50000;

003:12,Johnson,Cathy,44000;

004:13,Jones,Bob,55000;
```

Πίνακας 2–Αναπαράστασηαποθήκευσης δεδομένων σχεσιακής βάσης δεδομένων

Για να βελτιωθεί η απόδοση στην επεξεργασία των δεδομένων πρέπει να αποθηκεύονται με τρόπο για να ελαχιστοποιηθεί ο αριθμός των αναζητήσεων στα αρχεία ή τους δίσκους όπου αποθηκεύονται τα δεδομένα της βάσης. Ως λύση στο

πρόβλημα αποθήκευσης προτείνεται η στηλοκεντρική μέθοδος, όπως απεικονίζεται Πίνακα 3.

```
10:001,11:002,12:003,13:004;

Smith:001,Jones:002,Johnson:003,Jones:004;

Joe:001,Mary:002,Cathy:003,Bob:004;

40000:001,50000:002,44000:003,55000:004;
```

Πίνακας 3 - Αποθήκευση δεδομένων με την στηλοκεντρική μέθοδο

Τα συστήματα διαχείρισης βάσεων δεδομένων έχουν εξελιγμένους και βελτιστοποιημένους μηχανισμούς για να αποθηκεύουν τα δεδομένων τους, προκείμενου να λειτουργούν αποδοτικά εργασίες όπως είναι η τμηματοποίηση, η προσωρινή αποθήκευση και η δεικτοδότηση (partitioning, caching, indexing).

Στην περίπτωση που θα χρειαστεί η εισαγωγή μιας νέας οντότητας στο σύστημα τότε οι στηλοκεντρικές βάσεις δεδομένων είναι λιγότερο αποδοτικές από τις σχεσιακές διότι θα χρειαστεί ενημέρωση όλων των γραμμών της βάσης. Αντίθετα, στην περίπτωση προσθήκης ενός νέου πεδίου, αυτό θα γίνει πολύ εύκολα και αποδοτικά, με την προσθήκη μόνο μίας γραμμής στη βάση.

Επίσης, οι στηλοκεντρικές βάσεις έχουν μεγάλο πλεονέκτημα σε απόδοση στις περιπτώσεις επεξεργασίας υποσυνόλου των πεδίων της βάση, όπως για παράδειγμα σε πράξεις υπολογισμού μέγιστου, ελάχιστου, μέσου όρου και αθροίσματος ιδιαίτερα σε πολύ μεγάλα σύνολα δεδομένων.

2.5.1.2 Key-values Stores (Αποθήκες ζευγών κλειδιών – τιμών)

Αυτό το μοντέλο αποθήκευσης αποτελείται από έναν και μόνο πίνακα ο οποίος περιέχει 2 στήλες, οπού η πρώτη στήλη αφορά τα κλειδιά και η δεύτερη στήλη τις τιμές, ενώ κάθε κλειδί είναι μοναδικό. Οι τιμές αρχειοθετούνται και αργότερα θα προσπελαστούν με βάση τα κλειδιά. Χαρακτηριστική βάση που χρησιμοποιεί την

αποθήκευση ζευγών κλειδιών – τιμών είναι η MemcacheDB.Οι αποθηκών ζευγών κλειδιών – τιμών έχουν κύρια χρήση στην υλοποίηση συστημάτων προσωρινής μνήμης (caching).

Προκείμενου να κατανοηθεί το μοντέλο αποθήκευσης που χρησιμοποιούν οι αποθήκες ζευγών κλειδιών - τιμών, υπάρχει παρακάτω στον Πίνακα 4 μια αναπαράσταση βάσης όπως στο προηγούμενο παράδειγμα.

ΚΛΕΙΔΙ	**ΤΙΜΗ**
10_LASTNAME	**Smith**
10_FIRSTNAME	**Joe**
10_SALARY	**40.000**
11_LASTNAME	**Jones**
11_FIRSTNAME	**Mary**
11_SALARY	**50.000**
12_LASTNAME	**Johnson**
12_FIRSTNAME	**Cathy**
12_SALARY	**40.000**
13_LASTNAME	**Jones**
13_FIRSTNAME	**Bob**
13_SALARY	**55.000**

Πίνακας 4 – Αναπαράσταση της αποθήκευσης δεδομένων με την μέθοδο αποθήκης ζευγών κλειδιών - τιμών

2.5.1.3 Document-based stores (Αποθήκες εγγράφων)

Αυτή η κατηγορία βάσης δεδομένων η οποία αποκαλείται και εγγραφοκεντρική, δεν περιορίζεται από κάποιο σχήμα αλλά αποθηκεύει και οργανώνει τα δεδομένα σαν μια συλλογή από έγγραφα σε ημιδομημένους πίνακες, αφού οι χρήστες μπορούν προσθέσουν οι ίδιοι κάποιο πεδίο στον πίνακα χωρίς να υφίσταται κάποιος περιορισμός. Μια δημοφιλή λύση αποθήκης έγγραφων είναι το CoucheDBτο οποίο δημιουργήθηκε από τον οργανισμό ελεύθερου λογισμικούApache.

Για παράδειγμα, δύο εγγραφές μπορούν να έχουν διαφορετικά σύνολα πεδίων. Ακόμη και αν τα έγγραφα που δεν ακολουθούν ένα αυστηρό σχήμα, μπορεί να δημιουργηθούν ευρετήρια και να χρησιμοποιούνται στις ερωτήσεις. Στον Πίνακα 5παρουσιάζεταιη πρώτη εγγραφή από το παράδειγμα της προηγούμενης βάσης δεδομένων.

```
{       “EMP_ID”: “10”,
        “LASTNAME”: “Smith”,
        “FIRSTNAME”: “Joe”,
        “SALARY”: “40.000”,
}
```

Πίνακας 5–Αναπαράσταση εγγράφου

Ενώ, ένα δεύτερο έγγραφο μπορεί να μην έχει όλες τις πληροφορίες του προηγούμενου (μπορεί να μην έχει καθοριστεί ακόμα μισθός), όπως παρουσιάζεται στον Πίνακα 6.

```
{       “EMP_ID”: “11”,
        “LASTNAME”: “Jones”,
```

```
        “FIRSTNAME”: “Mary”,

}
```

Πίνακας 6–Αναπαράσταση εγγράφου με διαφορετικά δεδομένα

Ενώ ένα τρίτο έγγραφο μπορεί να έχει περισσότερα πεδία(όπως για παράδειγμα ο μισθός), ή να περιέχει και πίνακες, όπως απεικονίζεται και στον Πίνακα 7.

```
“EMP_ID”: “13”,

“LASTNAME”: “Jones”,

“FIRSTNAME”: “Bob”,

“ΜηνιαίεςΑπουσίες”:
[
{ “MONTH”: “Οκτώβριος”, “Απουσίες”: “1”} ,
{ “MONTH”: “Απρίλιος”, “Απουσίες”: “6”} ,
{ “MONTH”: “Μάιος”, “Απουσίες”: “18”} ,
]
```

Πίνακας 7 – Αναπαράσταση σύνθετου εγγράφου

Οι εγγραφοκεντρικές βάσεις παρέχουν αυτή την ευελιξία, δηλαδή να μετατρέπουν το σχήμα τους σε δυναμικό, δεδομένου της απεριόριστης ευελιξίας που αυτό προσφέρει, τις καθιστούν μια από τις δημοφιλείς επιλογές που χρησιμοποιούνται στις σημερινές διαδικτυακές εφαρμογές, όπου υπάρχει η ανάγκη αποθήκευσης διαφορετικών τύπων δεδομένων των οποίων τα χαρακτηριστικά αλλάζουν με τον καιρό ή ανάλογα με το συγκεκριμένο στοιχείο.

Αν και η εξέλιξη στην τεχνολογίας των εγγραφοκεντρικών βάσεων έχει ακόμη δρόμο να διανύσει, υπάρχουν ήδη αρκετές ώριμες και δημοφιλής λύσεις διαθέσιμες στην αγορά, οι χαρακτηριστικότερες των οποίων είναι οι: MongoDB, CouchDB και RavenDB.

2.5.1.4 Graph Databases

Οι βάσεις δεδομένων γραφών, με τις οποίες θα ασχοληθούμε διεξοδικά στο επόμενο κεφάλαιο, δεν χρησιμοποιούν πίνακες με γραμμές και στήλες ή μια άκαμπτη δομή. Βασίζονται στην θεωρία των γράφων και διαθέτουν ένα ευέλικτο μοντέλο γράφου το οποίο διαμοιράζεται σε πολλά μηχανήματα και προσαρμόζεται στις απαιτήσεις του χρήστη. Το ενδιαφέρον για αυτές τις βάσεις συνεχώς αυξάνεται αφού η κλασσική χρήση των βάσεων γίνεται για να απεικονίσουν δομές όπως τα κοινωνικά δίκτυα ή οι ιστοσελίδες του διαδικτύου, οπού οι σχέσεις μεταξύ των οντοτήτων είναι πολλές και περίπλοκες.

Αποτελούνται από *κόμβους* και *ακμές* που συνδέονται μεταξύ τους, ενώ χαρακτηρίζονται από ιδιότητες. Οι βάσεις δεδομένων γράφων έχουν σχεδιαστεί για να επιτρέπουν απλή και γρήγορη ανάκτηση πολύπλοκων ιεραρχικών δομών που είναι δύσκολο να μοντελοποιηθούν σε σχεσιακά συστήματα. Η καλύτερη χρήση για τις βάσεις δεδομένων γραφών είναι όταν οι σχέσεις επηρεάζουν τα ίδια τα δεδομένα.

Έχουν αναπτυχθεί αρκετές βάσεις δεδομένων γράφων οι σημαντικότερες εκ των οποίων είναι η Neo4j, η FlockDB και η InfiniteGraph.

2.6 NoSql ή Βάσεις Δεδομένων

Οι δύο τεχνολογίες, αυτή την των σχεσιακών βάσεων δεδομένων η οποία υφίσταται σχεδόν τρεις δεκαετίες αλλά και αυτή των βάσεων δεδομένων NoSQL, είναι κατάλληλες για διαφορετικούς τύπους εργασιών και εφαρμογών η καθεμιά, για αυτό στις επόμενες παραγράφους θα παρουσιαστούν τα κριτήρια αυτών των δύο τεχνολογιών, όπως αυτά έχουν σχηματιστεί μέχρι τώρα.

Οι σχεσιακές βάσεις δεδομένων επικεντρώνονται στις ιδιότητες ACID, επομένως κάθε δοσοληψία εξετάζεται για αυτές τις ιδιότητες και αν αυτές παραβιάζονται τότε η δοσοληψία απορρίπτεται. Από την άλλη πλευρά, οι βάσεις δεδομένων NoSQL δεν ακολουθούν τις ιδιότητες ACID για την αξιοπιστία της βάσης αλλά βασίζονται στο θεώρημα CAP.

Αρχικά, θα αναφερθούμε στις Σχεσιακές Βάσεις Δεδομένων και τις εργασίες που πραγματοποιούν οι οποίες αυξάνουν τον φόρτο εργασίας και αυτό με την σειρά προκαλούν καθυστερήσεις, οι διεργασίες αυτές είναι:

- Καταγραφή (Logging): οι παραδοσιακές ΒΔ καταγραφούν σε ένα αρχείο στο σκληρό δίσκο το πλήρες ιστορικό των ενεργειών που έχουν εκτελεστεί προκειμένου να διασφαλιστεί η μονιμότητα της ενέργειας.
- Κλείδωμα (Locking): εξασφαλίζεται η αποκλειστική πρόσβαση σε κάθε εγγραφή του πίνακα πριν από εγγραφές και η διαμοιραζόμενη πρόσβαση πριν από τις αναγνώσεις.
- Διαχείριση ενδιάμεσων μνημών (Buffermanagement): ο χρόνος προσπέλασης των πληροφοριών αυξάνεται αφού τα δεδομένα αποθηκεύονται σε σελίδες δίσκων προκαθορισμένου μεγέθους.

Τα συστήματα βάσεων δεδομένων NoSQL μπορούν με ευκολία να προσαρμόσουν το μοντέλο στα μέτρα τους, αφού δεν έρχονται αντιμέτωπα με τους ανωτέρω περιορισμούς των σχεσιακών ΒΔ. Πρέπει να σημειωθεί πως οι ΣΒΔ και τα χαρακτηριστικά τους ορισμένες φορές κυριαρχούν γεγονός που υποδεικνύει ότι αυτά τα χαρακτηριστικά έχουν τον κυρίαρχο λόγο για την επιλογή της κατάλληλης τεχνολογίας. Τα χαρακτηριστικά αυτά αναπτύσσονται παρακάτω:

- Αξιοπιστία: Οι βάσεις δεδομένων NoSQL δεν διαθέτουν τις ιδιότητες ACID αντίθετα με τις σχεσιακές βάσεις δεδομένων (ΣΒΔ), αυτό σημαίνει ότι εξασφαλίζουν αξιοπιστία μέχρι ενός σημείου αλλά όχι στο βαθμό που προσφέρουν οι ΣΒΔ. Για να εξασφαλιστούν τα χαρακτηριστικά των ιδιοτήτων ACID σε μια βάση δεδομένων NoSQLπρέπει να γίνει με την χρήση κώδικα.
- Πολυπλοκότητα: όπως ήδη έχουμε αναφέρει οι βάσεις δεδομένων NoSQL δεν χρησιμοποιούν τη γλώσσα SQL, επομένως για τις αναζητήσεις χρειάζεται είτε η συγγραφή κώδικα(πράγμα το οποίο είναι εύκολο στις απλές αναζητήσεις αλλά είναι χρονοβόρο και ίσως μη αποδοτικό σε περίπλοκες περιπτώσεις), είτε η εκμάθηση και χρήση μίας άλλης γλώσσας ερωτήσεων.
- Άγνωστη Τεχνολογία - ο φόβος για το καινούργιο, είναι γεγονός πως οι πιο πολλές εταιρίες νιώθουν ανασφάλεια σε σχέση με τη χρήση βάσεων δεδομένων NoSQLαφού δεν υπάρχει αρκετή εμπειρία στη χρήση τους. Έτσι, μερικές φορές επιλέγονται σχεσιακές βάσεις, παρόλο που στις

συγκεκριμένες περιστάσεις η χρήση βάσεων δεδομένων NoSQLθα ήταν η καλύτερη επιλογή.

3. Βάσεις Δεδομένων γράφων (GraphDataBase)

Όπως ήδη έχει αναφερθεί τα συστήματα διαχείρισης βάσεων δεδομένων ιεραρχούν και αποθηκεύουν τα δεδομένα σε συλλογές δεδομένων και μέσω των πινάκων σύνδεσης και με τη χρήση κλειδιών πραγματοποιείται η σύνδεση των δεδομένων. Αποτέλεσμα αυτής της διαδικασίας είναι να μειώνεται η αποδοτικότητα του συστήματος στην απάντηση περίπλοκων ερωτημάτων, ενώ –όπως αναφέρθηκε -η περιγραφή πολύπλοκων σχέσεων του πραγματικού κόσμου στις σχεσιακές βάσεις δεδομένων είναι δυσχερής.

Σήμερα, παρατηρείται έντονο ενδιαφέρον για τις βάσεις δεδομένων γράφων οι οποίες έχουν την δυνατότητα να αποθηκεύουν τα δεδομένα με μορφή γράφου. Έτσι, υπάρχει η δυνατότητα να απεικονίζονται με φυσικό τρόπο στη βάση δεδομένων όλες οι συνδέσεις που υφίστανται στον πραγματικό κόσμο.

3.1 Δομή Βάσης Δεδομένων Γράφων

Τα συστήματα βάσεων δεδομένων γράφων χρησιμοποιούν μορφές γράφων για την αναπαράσταση των δεδομένων, οπού περιλαμβάνουν κόμβους, ακμές και ιδιότητες. Οι κόμβοι (nodes) χρησιμοποιούνται για να αναπαριστούν οντότητες, όπως είναι για παράδειγμα τα άτομα ή οι επιχειρήσεις. Οι ακμές (edges) είναι οι συνδέσεις μεταξύ των κόμβων, δηλαδή αναπαριστούν τις σχέσεις ανάμεσα στους κόμβους. Οι κόμβοι και οι ακμές διαθέτουν ιδιότητες οι οποίες προσδιορίζουν τα χαρακτηριστικά τους.

Έχουν αναπτυχθεί αρκετές βάσεις δεδομένων γράφων όπως είναι: Neo4j, GraphDB, FlockdB, InfiniteGraphοπού σε κάθε εφαρμογή τα δεδομένα αποθηκεύονται και υποβάλλονται ερωτήσεις στον γράφο.

Ουσιαστικά, οι βάσεις δεδομένων γράφων είναι μια αναπτυσσόμενη τεχνολογία βάσεων δεδομένων και θα μπορούσε να οριστεί ως ένα μοντέλο βάσεων δεδομένων το οποίο αναπαριστά την δομή των δεδομένων είτε ως κατευθυνόμενους γράφους είτε με γενικές δομές γράφων, οπού ο χειρισμός των δεδομένων πραγματοποιείται μέσω διάφορων τεχνικών που εφαρμόζονται στους γράφους και η ακεραιότητα των δεδομένων περιορίζεται στην δομή των γράφων. στους γράφους υφίστανται οι δύο ακόλουθες έννοιες

- Hypernodes (υπερ–κόμβοι): αναφέρεται στην ενθυλάκωση των γράφων, δηλαδή ένας κόμβος μπορεί να αναπαριστά έναν άλλο ολόκληρο γράφο.

➢ Hyperedges (υπερ-ακμές): μια υπερ-ακμή δεν συνδέει μόνο 2 κόμβους αλλά εκφράζει τη σχέση μεταξύ ενός κόμβου από τη μία πλευρά και ενός ακαθόριστου αριθμού κόμβων από την άλλη πλευρά.

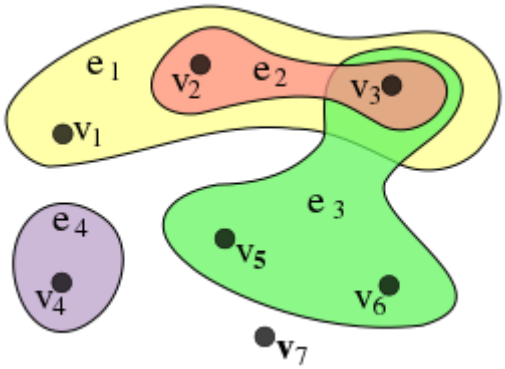

Εικόνα 4 – Απεικόνιση hypernodes&hyperedges. Η υπερ-ακμή e1 εκφράζει μία σχέση ανάμεσα στις κορυφές v1, v2, v3, ενώ η ακμή e3 εκφράζει μία σχέση ανάμεσα στις κορυφές v3, v5 και v6 κ.ο.κ.

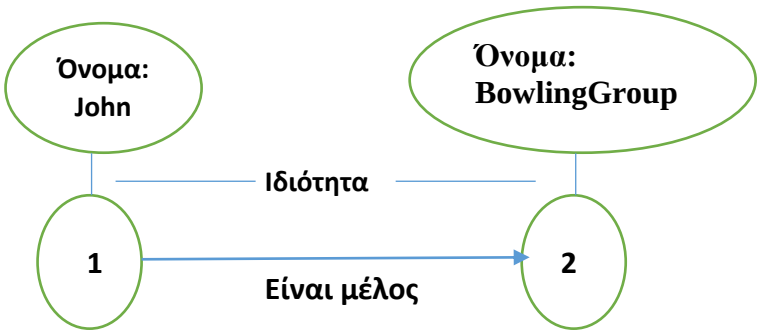

Εικόνα 5 – Αναπαραστάση ενός στιγμιότυπου βάσης δεδομενών γράφων

Η εικόνα 4 αποτελείται από 2 κόμβους (1,2), έχει μια ακμή με ετικέτα "Είναι μέλος", ενώ ό κάθε κόμβος έχει μια ιδιότητα "όνομα". Στην προκειμένη περίπτωση η ακμή του γράφου διαθέτει ένα βέλος γεγονός που δείχνει ότι ο γράφος είναι κατευθυνόμενος.

Ωστόσο, η ακμή ενός γράφου μπορεί να είναι είτε κατευθυνόμενη (directed) είτε μη κατευθυνόμενη (undirected), ωστόσο πιο συχνά στις βάσεις δεδομένων χρησιμοποιούνται οι γράφοι που διαθέτουν κατευθυνόμενες ακμές.

3.2 Πλεονεκτήματα Βάσεων Δεδομένων Γράφων

Σύμφωνα με τον ιδρυτή της Neo4j, Emil Eifrem, οι λόγοι για τους οποίους οι βάσεις δεδομένων γράφων είναι οι προτιμότερες είναι οι ακόλουθοι.

Σήμερα, οι περισσότερες εφαρμογές χειρίζονται δεδομένα τα οποία είναι δομημένα ως γραφήματα, δηλαδή διαθέτουν βαθιές και πολύπλοκες συσχετίσεις. Χαρακτηριστικά παραδείγματα αποτελούν οι ιστότοποι των μέσων κοινωνικής δικτύωσης αλλά και τα συστήματα διαχείρισης περιεχόμενου τα οποία ασχολούνται είτε με εγγενώς ιεραρχικά δεδομένα είτε με δεδομένα σε μορφή γραφήματος.

Ουσιαστικά, το πρόβλημα εστιάζεται στο γεγονός πως δεν μπορούν να με φυσικό και αποτελεσματικό τρόπο να αντιμετωπιστούν οι αναδρομικές σχέσεις με τις παραδοσιακές σχεσιακές βάσεις δεδομένων. Με δεδομένο ότι το περιεχόμενο των δεδομένων το οποίο καθοδηγείται από τον χρήστη, είναι δύσκολο να προκαθορισθεί το ακριβές σχήμα των δεδομένων που θα χειριστεί μία εφαρμογή, και στο σχεσιακό μοντέλο η ύπαρξη προκαθορισμένου μοντέλου είναι απαραίτητη.

Μια βάση δεδομένων γράφων χρησιμοποίει κόμβους, ακμές μεταξύ των κόμβων αλλά και τις ιδιότητες για να αντιπροσωπεύουν τις πληροφορίες, αντί για πίνακες. Το μοντέλο των βάσεων δεδομένων γράφων είναι ταχύτατο σε μεγάλα σύνολα δεδομένων, αφού το μοντέλο που χρησιμοποίει δεν βασίζεται σε προκαθορισμένα σχήματα και είναι επίσης ιδανικό για εφαρμογές λήψης αποφάσεων.

3.3 Σύγκριση Βάσεων Δεδομένων Γραφών και Σχεσιακών Βάσεων Δεδομένων

Οι διαφορές μεταξύ των μοντέλων βάσεων δεδομένων γράφων και των μοντέλων σχεσιακών βάσεων δεδομένων είναι αρκετές. Οι πιο σημαντικές από αυτές τις διαφορές αναφέρονται παρακάτω.

Στο σχεσιακό μοντέλο τα δεδομένα καταχωρούνται σε μια δομή η οποία είναι γνωστή εκ των προτέρων. Αντίθετα, στις βάσεις δεδομένων γράφων η δομή της

βάσης δεδομένων γράφων μπορεί να τροποποιηθεί ανάλογα με τις απαιτήσεις. Όσον αφορά την επεκτασιμότητα οι σχεσιακές βάσεις δεδομένων επεκτείνονται δύσκολα αφού το σχήμα είναι σταθερό, ενώ στις βάσεις δεδομένων γράφων έχουν απόλυτη ευελιξία στο περιεχόμενο που θα αποθηκεύσουν.

Οι βάσεις δεδομένων γράφων διαθέτουν μεθόδους προκειμένου να δημιουργούν συσχετίσεις μεταξύ των δεδομένων, ενώ στις σχεσιακές βάσεις δεδομένων η γλώσσα ερωτημάτων δεν είναι σε θέση να εντοπίζει συσχετίσεις που μπορεί τα δεδομένα να έχουν μεταξύ τους.

Ακόμα, οι βάσεις δεδομένων γράφων προσφέρουν υψηλή απόδοση στη διαχείριση των συνδεδεμένων δεδομένων ωστόσο στις σχεσιακές βάσεις δεδομένων οι συνδέσεις μεταξύ των πινάκων δημιουργούν μείωση στην απόδοση του συστήματος όσο ο όγκος των δεδομένων αυξάνεται, πράγμα το οποίο δεν ισχύει στις βάσεις δεδομένων γράφων η απόδοση παραμένει σταθερή.

Μια βάση δεδομένων γράφων είναι η neo4j, η οποία θα αναλυθεί παρακάτω, όπως παρουσιάζεται στην Εικόνα 6 απεικονίζει την απόδοση της neo4j που όσο ο όγκος των δεδομένων αυξάνεται παραμένει σχεδόν σταθερή, ενώ, στα σχεσιακά συστήματα όσο ο όγκος των δεδομένων αυξάνεται τόσο μειώνεται η απόδοση (αυξάνεται ο χρόνος απόκρισης).

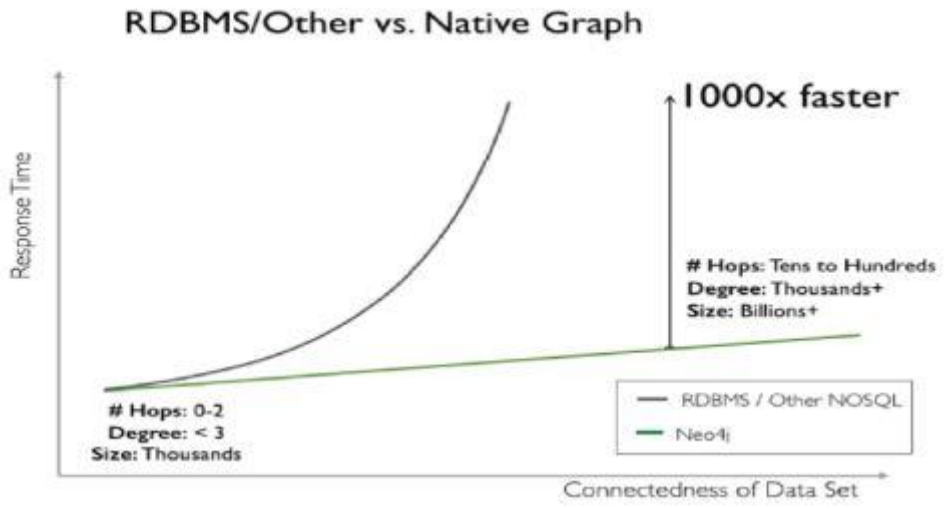

Εικόνα 6 – Σύγκριση σχεσιακών βάσεων δεδομένων και βασέων δεδομένων γράφων στην αύξηση των δεδομένων

3.4 Συστήματα Βάσεων Δεδομένων Γράφων

Σήμερα υπάρχουν αρκετά συστήματα βάσεων δεδομένων γράφων οι οποίες έχουν δημιουργηθεί μέχρι σήμερα. Θα παρουσιαστούν μερικά λογισμικά με διαφορετικά χαρακτηριστικά, τα οποία είναι: Neo4j, Graph DB, Infinite Graph και η Cayley.

3.4.1 Neo4j

Η βάση δεδομένων γράφων Neo4jείναι γραμμένη σε γλώσσα Java, είναι ανοιχτού κώδικα, δημιουργήθηκε από την εταιρία NeoTechnology και κυκλοφόρησε το 2010.

Η Neo4j χρησιμοποιεί ένα σύνολο από κόμβους και κατευθυνόμενες ακμές, ενώ κάθε κόμβος και κάθε ακμή διαθέτει ένα σύνολο ιδιοτήτων προκειμένου να αποθηκεύονται τα δεδομένα. Υποστηρίζει μόνο κατευθυνόμενους κόμβους και για αν υφίσταται αμφίδρομη σχέση μεταξύ των κόμβων τότε πρέπει να υπάρχουν 2 συσχετίσεις ανάμεσα τους.

Προκείμενου να θέτουμε αιτήματα, δηλαδή να θέτονται ερωτήσεις και να δίνονται απαντήσεις χρησιμοποιείται η γλώσσα Cypher, η οποία είναι αρκετά εύκολη για τους χρήστες οι οποίοι γνωρίζουν SQL(η οποία χρησιμοποιείται στις σχεσιακές βάσεις δεδομένων). Η Neo4j είναι ικανή να διαχειρίζεται γράφους αρκετών δισεκατομμυρίων κόμβων, σχέσεων και ιδιοτήτων, αφού διασχίζει 1.000.000 συσχετίσεις/δευτερόλεπτο.

Η Neo4j αποτελεί μια βάση δεδομένων γράφων η οποία διατηρεί τις ιδιότητες ACID, έτσι είναι ικανή να διατηρεί πλήρως την ακεραιότητα των δεδομένων, αλλά και την απομόνωση των δοσοληψιών, δηλαδή μέχρι να ολοκληρωθεί μια δοσοληψία αποκρύπτει τις αλλαγές από άλλες διεργασίες.

3.4.2AllegroGraph

Η AllegroGraph είναι ένα λογισμικό κλειστού κώδικα για διαχείριση βάσεων δεδομένων γράφων που, το οποίο είναι σχεδιασμένο να αποθηκεύει τριπλέτες RDF.

Το RDF (ResourceDescriptionFramework) είναι ένα πρότυπο για τη μορφοποίηση δομημένων δεδομένων ή μετα-δεδομένων. Χρησιμοποιείται σε διάφορα έργα ανοιχτού λογισμικού, καθώς και σε εμπορικά έργα και έργα κυβερνητικών ή μη οργανισμών. Είναι επίσης υπεύθυνη για την αποθήκευση δεδομένων για το έργο TwitLogic το οποίο εφαρμόζει την λογική του Σημασιολογικού Ιστού στα δεδομένα του Twitter.

Είναι ένα προϊόν της εταιρίας Franz Inc. η οποία αποτελεί κορυφαίο προμηθευτή για εμπορικές βάσεις δεδομένων RDF που διαθέτουν αυξημένες δυνατότητες κλιμάκωσης. Η πρώτη έκδοση της AllegroGraph ήταν διαθέσιμη το 2004.

Η AllegroGraph χρησιμοποίει την SPARQL, η οποία είναι μια πρότυπη γλώσσα ερωτήσεων για συνδεδεμένα δεδομένα, εξυπηρετώντας τους ίδιους σκοπούς για βάσεις δεδομένων RDF. Είναι πλέον διαθέσιμη για όλες τις πλατφόρμες υλικού και λογισμικού.

Η AllegroGraph παρέχει μια ευρεία σειρά μηχανισμών αναζήτησης και πρόσβασης σε μια βάση δεδομένων RDF:

- **Μηχανή RDFS++:**Η AllegroGraph προσφέρει έναν πολύ γρήγορο και πρακτικό μηχανισμό συμπερασμού RDFS.Ο μηχανισμός RDFS ++ της AllegroGraph διατηρεί με δυναμικό τρόπο το οντολογικό υπόβαθρο που απαιτείται για την εκτέλεση συμπερασμών και δεν περιλαμβάνει διακριτή φάση προ-υπολογισμού και αποθήκευσης συναχθεισών τριπλετών (materialization) ώστε να . εκτελούνται πιο αποτελεσματικά τα ερωτήματα. Το ουσιαστικό πρόβλημα με τη διαδικασία του materialization είναι η συντήρησή του, αφού οποιαδήποτε αλλαγή στα πρωτογενή δεδομένα απαιτεί πλήρη επανεπεξεργασία πριν από την εμφάνιση νέων ερωτημάτων. Η δυναμική εκτέλεση του materializationτου AllegroGraph απλοποιεί τη συντήρηση της βάσης και μειώνει τον απαιτούμενο χρόνο μεταξύ των αλλαγών στα δεδομένα και της εκτέλεσης των ερωτήσεων.
- **Ερωτήματα SPARQL:**Η AllegroGraph υλοποιεί τη SPARQL, την πρότυπη γλώσσα ερωτημάτων σε βάσεις δεδομένων RDF του W3C, η οποία μπορεί να επιστρέφει απαντήσεις σε RDF ήXML. Η υλοποίηση SPARQL της AllegroGraph ακολουθεί τα πρότυπα διαλειτουργικότητας του W3C,

περιλαμβάνει ένα εργαλείο βελτιστοποίησης επερωτήσεων και παρέχει πλήρη υποστήριξη για χειρισμό γράφων.

- **Prolog:** HRDF Prolog της AllegroGraph παρέχει ισχυρές δυνατότητες για διεξαγωγή συμπερασμών με βάση πολύπλοκους κανόνες ή εκτεταμένη επεξεργασία, πάνω σε δεδομένα RDF. Η εκτέλεση αυτών των συμπερασμών είναι εξαιρετικά δυσχερές να πραγματοποιηθεί μόνο με χρήση RDF/RDFSκαι OWL, συνεπώς η Prologπαρέχει τα απαραίτητα εργαλεία ώστε να κτιστεί ένα σύστημα κανόνων συμπερασμού πάνω από τον βασικό μηχανισμό συμπερασμού RDFS++.
- **Σύντομη, ισχυρή, βασισμένη βιομηχανικά standards**, εξειδικευμένη για την δημιουργία εννοιών υψηλού επιπέδου (που απαιτούν σύνθετους κανόνες ή επεξεργασία) πάνω σε δεδομένα RDF. Έτσι είναι δύσκολο (ή πολύ περίεργο) να μοντελοποιήσουμε δεδομένα μόνο με RDF / RDFS και OWL. Η Prolog μπορεί επίσης να χρησιμοποιηθεί μαζί με το RDFS++ ως ένα σύστημα βασισμένο σε κανόνες.
- **API χαμηλού επιπέδου**: Παρέχει εξαιρετικά ταχεία πρόσβαση στις τριπλέτες, με βάση τα εσωτερικά χαρακτηριστικά υλοποίησης της AllegroGraph.

Η AllegroGraph υλοποιεί και παρέχει διεπαφές τύπου REST, ενώ έχει επίσης σχεδιαστεί έτσι ώστε οι πόροι του υλικού να αξιοποιούνται με βέλτιστο τρόπο σε όλες τις διαδικασίες διαχείρισης δεδομένων. Η αξιοποίηση του υλικού πραγματοποιείται μέσω του αρχείου διαμόρφωσης της AllegroGraph. Υποστηρίζει απευθείας διασυνδέσεις για διάφορες γλώσσες, Sesame Java, Sesame Jena, Python χρησιμοποιώντας τις Sesame και Lisp. Παράλληλα, η κοινότητα των χρηστών έχει δημιουργήσει διασυνδέσεις ανοικτού κώδικα για C #, Ruby, Clojure, Scala και Perl. Τέλος, παρότι η AllegroGraph ανήκει στις βάσεις δεδομένων γράφων, εφαρμόζει τις ιδιότητες ACID.

3.4.3 Oracle Spatial and Graph

Καθώς οι εφαρμογές εξελίσσονται, αφού εμφανίζονται νέες τεχνολογίες και πλατφόρμες, βρίσκονται συνεχώς νέοι τρόποι για να ενσωματωθούν και να αξιοποιηθούν οι πληροφορίες από τα κοινωνικά δίκτυα. Η εμφάνιση των υπηρεσιών

Cloud, της παρακολούθησης μέσω κινητού τηλεφώνου, των κοινωνικών μέσων και των συστημάτων πραγματικού χρόνου δημιουργούν νέες προκλήσεις για τη διαχείριση του όγκου των δεδομένων, αλλά κυρίως για την ανακάλυψη συνδέσεων και σχέσεων.

Για να αντιμετωπιστούν όλες οι παραπάνω προκλήσεις, δημιουργήθηκε το Oracle Database 12cη οποία περιλαμβάνει ένα ευρύ φάσμα λειτουργιών και υπηρεσιών χωρικής ανάλυσης για την αποτίμηση συνθηκών στα δεδομένα με βάση το πόσο κοντά μία οντότητα είναι σε μία άλλη, εάν μία οντότητα βρίσκεται εντός μίας περιοχής, ή για την οπτικοποίηση μοτίβων σε χάρτες και εικόνες. Με την Oracle Database 12cπου βασίζεται στο OracleCloud, η Oracleεισάγει μία νέα δυνατότητα ανάλυσης γράφων με βάση τις ιδιότητες για να αντιμετωπίσει τυπικές αλλά και καινοτόμες περιπτώσεις χρήσης γράφων, συμπεριλαμβάνοντας τη διαμόρφωση συστάσεων, τον εντοπισμό κοινοτήτων και οντοτήτων υψηλής επιρροής (influencers), ταίριασμα μοτίβων και εντοπισμό απάτης. Στη βάση δεδομένων αποθηκεύονται με φυσικό τρόπο τα δεδομένα τα οποία δημιουργούνται από εγγενείς σχέσεις μεταξύ των οντοτήτων του πραγματικού κόσμου, οπού οι κόμβοι του γράφου υποδεικνύουν τις οντότητες, τα άκρα υποδηλώνουν τις σχέσεις και οι ιδιότητες αποθηκεύονται ως ζεύγος κλειδιών – τιμών.

Η ευκολία στην ανάπτυξη εφαρμογών και η διαχείριση των δεδομένων επιτυγχάνεται μέσω μια κονσόλας βασισμένης στο Groovyκαι ένα σύνολο JavaAPI για τη δημιουργία και τη διαχείριση των γράφων, την αφαίρεση κόμβων και ακμών και την αναζήτηση κόμβων και ακμών χρησιμοποιώντας ζεύγη κλειδιών-τιμών. Τα API της Java περιλαμβάνουν την υλοποίηση των διεπαφών Apache TinkerPop.

Η γρήγορη και παράλληλη φόρτωση μεγάλων γράφων επιτυγχάνεται με τη χρήση μιας ειδικής μορφής αρχείου, σχεδιασμένης από την Oracle και ενός βοηθητικού προγράμματος για την εύκολη μετατροπή των πινάκων Oracle και των αρχείων CSV (CSV) σε αυτή τη μορφή. Επίσης, υποστηρίζονται τα ανοικτά πρότυπα γράφων GraphSON, GraphML και GML.

Το χωρικό φιλτράρισμα στα ερωτήματα γράφων μπορεί να βελτιώσει την αποτελεσματικότητα της ανάλυσης γράφων. Μια χωρική γεωμετρία, όπως οι συντεταγμένες μιας διεύθυνσης, μπορεί να αποθηκευτεί ως ιδιότητα και να αναλυθεί.

Για παράδειγμα, ένα ερώτημα "εντός απόστασης" μπορεί να καθορίσει αν θα εξεταστεί μία συνδεδεμένη οντότητα στα υπόλοιπα βήματα της ανάλυσης. Η υποστήριξη γεωμετρικών σημείων, γραμμών και πολυγώνων και η χωρική ευρετηρίαση με βάση τις λειτουργίες και η πρόσβαση σε χωρικές λειτουργίες ανάλυσης αυξάνουν σημαντικά την ισχύ του συγκεκριμένου χαρακτηριστικού.

3.4.4 OpenLink Virtuoso

Το σύστημα βάσεων δεδομένων Virtuoso, γνωστό ως και Virtuoso Universal Server, είναι ένα ενδιάμεσο λογισμικό και μηχανισμός βάσης δεδομένων που συνδυάζει τη λειτουργικότητα ενός παραδοσιακού συστήματος διαχείρισης βάσεων δεδομένων (RDBMS), βάσης δεδομένων σχεσιακών αντικειμένων (ORDBMS), εικονικής βάσης δεδομένων με περιεχόμεναRDF, XML, ελεύθερου κειμένου, διακομιστή web server και λειτουργικότητα διακομιστή αρχείων σε ένα ενιαίο σύστημα.

Αντί να διατηρούμε ξεχωριστούς διακομιστές για κάθε ένα από τα προαναφερθέντα πεδία λειτουργικότητας, το Virtuoso είναι ένας "καθολικός διακομιστής". Ενοποιεί πολλαπλούς διακομιστές υλοποιώντας πολλαπλά πρωτόκολλα. Ο διακομιστής Virtuoso είναι σχεδιασμένος με υποστήριξη για πολλαπλά νήματα ελέγχου και υποστήριξη για εκτέλεση σε συστήματα με πολλαπλούς επεξεργαστές.

Για την χρήση ερωτημάτων υποστηρίζει τη SPARQL και είναι συμβατή με τη Jena, οπού η SPARQL μεταφράζεται σε SQL κατά την ανάλυση του ερωτήματος. Όλες οι τριπλέτες αποθηκεύονται σε έναν μοναδικό πίνακα.

Η Virtuoso υποστηρίζεται από μεγάλο αριθμό πλατφορμών, τόσο 32 bit όσο και 64 bit (Windows, UNIX, Linux (RedHat, SUSE, MacOSX). Έχει τη δυνατότητα να διαχειρίζεται αποτελεσματικά πάνω από 1 δισεκατομμύριο τριπλέτες.

3.4.5 GraphDB

Η GraphDB, που αρχικά ονομαζόταν SonesGraphDB, είναι μια βάση δεδομένων γράφων η οποία αναπτύχθηκε από τη εταιρία Sones και ήταν διαθέσιμη από το 2010 μέχρι το 2012. Το 2014 εξαγοράστηκε από την εταιρία Ontotext και μετονομάστηκε, λαμβάνοντας το σημερινό της όνομα. Έχει αναπτυχθεί σε C# και τρέχει σε πλατφόρμα.Net.

Το λογισμικό αυτό συνδέεται με μια βάση δεδομένων και παρέχει τη δυνατότητα υποβολής και επεξεργασίας ερωτημάτων σχετικά με αυτή τη βάση δεδομένων. Στη συνέχεια οι απαντήσεις από τα ερωτήματα παρουσιάζονται φυσικά και διαισθητικά. Η πρόσβαση στα δεδομένα πραγματοποιείται μέσω της γλώσσας GQL (GraphQueryLanguage) η οποία χρησιμοποίει μια επέκταση της SQL που έχει προσαρμοστεί για να αλληλεπιδρά με βάσεις δεδομένων γράφων.

Όσον αφορά το σχήμα της βάσης δεδομένων γράφων GraphDB, αυτό αποτελεί επέκταση ενός γράφου. Πολλαπλές ακμές μπορούν να ομαδοποιούνται σε μία υπερ-ακμή (hyperedge), κάθε μία από τις οποίες η οποία μπορεί να αποκτήσει τις δικές της ιδιότητες: για παράδειγμα οι ιδιότητες μπορεί να επιτρέπουν την χρήση υπολογισμών μεταξύ του συνόλου των κόμβων.

3.4.6 InfiniteGraph

Η InfiniteGraph αποτελεί το σύστημα βάσης δεδομένων γράφων της εταιρείας Objectivity, η οποία αναπτύσσει βάσης δεδομένων με υψηλή δυνατότητα κλιμάκωσης και πραγματοποίει κατανεμημένη διαχείριση δεδομένων. Είναι γραμμένη σε Java, είναι διαθέσιμη στο κοινό από το 2010, ανήκει στην κατηγορία των βάσεων δεδομένων NoSQLκαι επικεντρώνεται στις βάσεις δεδομένων γράφων.

Οι προγραμματιστές χρησιμοποιούν την InfiniteGraph για μεγάλα σύνολα συνδεδεμένων δεδομένων. Η GraphDBείναι συμβατή με όλα τα λειτουργικά συστήματα, είναι επεκτάσιμη και διαχειρίζεται τα δεδομένα με υψηλή απόδοση.

Η InfiniteGraph είναι κατάλληλη για εφαρμογές και οι υπηρεσίες οι οποίες λύνουν προβλήματα γράφων ή είναι σε θέση να απαντούν σύνθετα ερώτημα όπως είναι για

παράδειγμα “Ποια αεροπορική εταιρία διαθέτει τα φθηνότερα αεροπορικά εισιτήρια με επιστροφή για έναν συγκεκριμένο προορισμό, με 2 στάσεις το πολύ και να αναχωρεί συγκεκριμένη μέρα και ώρα”.

Οι εφαρμογές συνδέονται σε ένα κατανεμημένο σύστημα στο οποίο η InfiniteGraph χρησιμοποίει ένα δικό της διακομιστή αρχείων με όνομα AMS, προκειμένου να ενορχωστρωθεί η πρόσβαση στα δεδομένα.

Το περιβάλλον της InfiniteGrapheίναι απλό και σκοπό του είναι να αναδείξει την δομή του γράφου, προσφέροντας εύκολη διαχείριση. Επίσης, διαθέτει μία ευέλικτη εφαρμογή πλοήγηση ς η οποία προσαρμόζεται ανάλογα με τις ανάγκες του μοντέλου. Οι κόμβοι εμφανίζονται μαζί με τις συνδέσεις τους και υπάρχει λεπτομερής εμφάνιση των δεδομένων όταν επιλέγει ένα σημείο του γράφου.

Αυτή η βάση δεδομένων γράφων φαίνεται να έχει αποδοχή από οργανισμούς οι οποίοι ασχολούνται με την υγειονομική περίθαλψη, σε εφαρμογές κοινωνικής δικτύωσης ή εταιρίες που παρέχουν υπηρεσίες ασφάλειας στο διαδίκτυο.

3.4.7 Cayley

Η βάση δεδομένων γράφων Cayley χρησιμοποιείται για εφαρμογές οι οποίες βασίζονται σε γραφήματα σχετιζομένων πληροφοριών . Η Cayley διατίθεται δωρεάν και είναι εύκολη στην χρήση της.

Η αφετηρία για την Cayley υπήρξε Γράφος γνώσης της Google ο οποίος χρησιμοποιείται σε μια αναζήτηση και είναι μια βάση δεδομένων “γνώσης”. Ουσιαστικά, σκοπός του είναι να βελτιώσει τα αποτελέσματα της αναζήτησης μέσα από μια γραφική προβολή των πληροφορίων, οι οποίες συλλέγονται από πολλές πηγές. Οι πληροφορίες εμφανίζονται δομημένες σχετικά με το θέμα της αναζήτησης, ενώ παρουσιάζονται και συνδέσεις με άλλους ιστότοπους οι οποίοι ενδέχεται να αφορούν το θέμα αναζήτησης.

Έτσι λοιπόν γνωρίζοντας τη σημασία του γράφου γνώσης, οι προγραμματιστές της Google θέλησαν να δημιουργήσουν μια ανοιχτού κώδικα βάση δεδομένων γράφων για προγραμματιστές εκτός Google, και το αποτέλεσμα είναι η Cayley, η οποία πήρε

το όνομα της από τον μαθηματικό Arthur Cayley ο οποίος είναι υπεύθυνος για το θεώρημα γράφων Cayley.

Η Caley είναι πνευματικός διάδοχος του συστήματος GraphD με το οποίο μοιράζεται την ίδια στρατηγική στην αποτίμηση των ερωτήσεων για την επίτευξη ταχύτητας. Είναι γραμμένη με την γλώσσα Go, η οποία είναι κατάλληλη για υλοποίηση backendυπηρεσιών με υψηλή ταχύτητα και δυνατότητα ταυτόχρονης πρόσβασης στα δεδομένα. Η Cayley αξιοποιεί τις εκτενείς βιβλιοθήκες της γλώσσας Go, οι οποίες διευκολύνουν σε σημαντικό βαθμό την ταυτόχρονη πρόσβαση στα δεδομένα.

4. CAYLEY

Σε αυτό το κεφαλαίο, περιγράφεται η βάση δεδομένων γράφων Cayley, η διαδικασία εγκατάστασης της, η γλώσσα ερωτημάτων που χρησιμοποίει η οποία είναι Gremlin.

4.1 Περιγραφή Cayley

Η Cayley ανήκει στις βάσεις δεδομένων γράφων και είναι πνευματική διάδοχος του προγράμματος GraphD, με το οποίο διαμοιράζεται την ίδια στρατηγική στα queries προκειμένου να επιτευχθεί υψηλή ταχύτητα.

Ουσιαστικά, δεν διαφέρει από τον προκάτοχο της αφού παρέχει τα έξης χαρακτηριστικά:

- ΥποστήριξηRestful API.
- Πολλαπλοί τρόποι αποθήκευσης, όπως είναι η MongoDB.
- Υποστήριξη για πολλές γλώσσες ερωτημάτων
- Ευκολία στην χρήση για αρχάριους
- Μπορεί να χρησιμοποιηθεί σαν βιβλιοθήκη για τη κατασκευή περίπλοκων εφαρμογών.
- Είναι λογισμικού ανοιχτού κώδικα.

Η Cayley χρησιμοποίει κόμβους, ακμές και ιδιότητες και έχει σχεδιαστεί έτσι ώστε να επιτρέπει την απλή και γρήγορη ανάκτηση σύνθετων ιεραρχικών δομών τα οποία δύσκολα μοντελοποιούνται στα σχεσιακά συστήματα.

Τα 3 κύρια μέρη της βάσης δεδομένων γράφων Cayley είναι οι κόμβοι, οι άκρες και οι ιδιότητες, οπού:

- Οι κόμβοι αντιπροσωπεύουν μια οντότητα, όπως είναι για παράδειγμα ένα άτομο.

- Μια άκρη καθορίζει την σχέση μεταξύ των 2 κόμβων. Μια άκρη θα έχει πάντα μια κατεύθυνση, θα εξέρχεται από έναν κόμβο και θα εισέρχεται σε έναν άλλο.
- Η ιδιότητα περιγράφεται με ένα ζεύγος κλειδιού – τιμής η οποία προσδίδεται σε έναν κόμβο ή μια άκρη.

4.2 Εγκατάσταση Εφαρμογής Cayley

Πραγματοποιείται η εγκατάσταση της βάσης δεδομένων γράφων Cayley για το λειτουργικό σύστημα windows, οπού η διαδικασία η οποία απαιτείται περιγράφεται παρακάτω.

Αρχικά, από τον ιστότοπο της Cayley https://cayley.io/και επιλέγοντας την εντολή Download Cayley, εμφανίζεται μια λίστα με διάφορες εκδόσεις της, οπού επιλέγεται η κατάλληλη σύμφωνα με το λειτουργικό σύστημα του υπολογιστή μας.

Στην συνέχεια, μόλις ολοκληρωθεί το κατέβασμα πρέπει να αποσυμπιεστεί ο φάκελος με τα αρχεία.

Έπειτα, μετά την αποσυμπίεση του φακέλου, κάθε φόρα που θα πραγματοποιείται χρήση της Cayley, η διαδικασία έχει ως έξης:

1. Με την χρήση draganddrop, σύρουμε τα αρχεία του φακέλου Data, στην εφαρμογή cayley.exe
2. Πραγματοποιείται άνοιγμα της γραμμής εντολών (commandprompt), γράφοντας την εντολή cmd στην γραμμή αναζήτησης.
3. Μετά το άνοιγμα του παραθύρου εντολών πληκτρολογείτε η εντολή cd (changedirectoy) και σύρουμε όλο τον αποσυμπιεσμένο φάκελο cayley_v0.6.1_windows_386, το αποτέλεσμα απεικονίζεται στην Εικόνα 7.

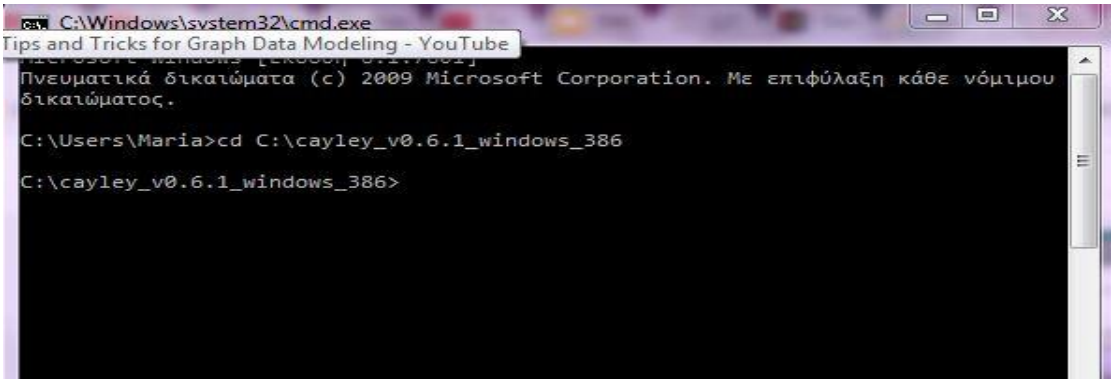

Εικόνα 7– Αλλαγή διεύθυνση φακέλου προορισμού

4. Έπειτα συνεχίζουμε στην γραμμή εντολών γράφοντας την εντολή cayley.exe http --dbpath="30kmoviedata.nq.gz", όπως φαίνεται και στην Εικόνα 8.

Εικόνα 8 – Διεύθυνση Cayley

5. Μετά την παραπάνω διαδικασία εμφανίζεται μια διεύθυνση, οπού στην προκείμενη περίπτωση είναι http://127.0.0.1:64210/
6. Σε ένα browser της επιλογή μας την πληκτρολογούμε και εμφανίζεται το περιβάλλον της Cayley, όπως δείχνει και η Εικόνα 9.

Εικόνα 9 – Περιβάλλον Cayley

4.3 Το περιβάλλον της Cayley

Το περιβάλλον της Cayley αποτελείται από τα ερώτημα (query), το query shape, την απεικόνιση των ερωτημάτων (visualize), και το πεδίο write, όπως δείχνει και η Εικόνα 10.

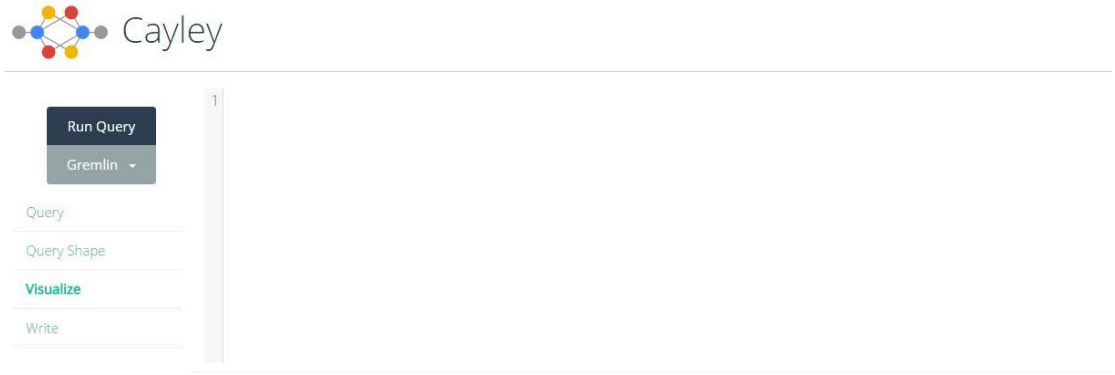

Εικόνα 10 – Περιβάλλον Cayley

Στο πεδίο ερώτημα (query) δημιουργείται ένα ερώτημα είτε με τη γλώσσα Gemlin είτε με τη γλώσσα Gizmo, και πατώντας το κουμπί RunQuery, εμφανίζεται το αποτέλεσμα της ερώτησης. Στο πεδίο query shape, υπάρχει μόνο μια απεικόνιση του ερωτήματος, χωρίς να υπάρχει η δυνατότητα δημιουργίας ερωτήματος.

Στο πεδίο απεικόνιση (virtualize) εκτελείται ένα ερώτημα, και αν αυτό έχει δημιουργηθεί σωστά, θα επιστρέψει σαν αποτέλεσμα μια εικόνα από κόμβους. Πιο συγκεκριμένα, για να χρησιμοποιήσετε τη λειτουργία απεικόνισης, θα πρέπει να παραχθούν, είτε μέσω ετικετών (tags) είτε επεξεργασίας με Javascript, ένα σύνολο αντικειμένων JSON που περιέχουν τα κλειδιά πηγή (source) και στόχος (target). Αυτοί θα είναι οι σύνδεσμοι και οι κόμβοι θα ανιχνευθούν αυτόματα.

Η λειτουργία απεικόνισης προσπαθεί να ανιχνεύσει τους κόμβους είτε ως "πηγή" είτε ως "στόχο". Η πηγή σας αντιπροσωπεύεται ως μπλε κόμβος. Ενώ ο στόχος σας αντιπροσωπεύεται ως πορτοκαλί κόμβος. Η ιδέα είναι ότι η σχέση κόμβων μας πηγαίνει από μπλε σε πορτοκαλί (πηγή προς στόχο).

Τέλος στο πεδίο write υπάρχει η δυνατότητα στη διεπαφή να εγγράψει ή να αφαιρέσει μεμονωμένες τετράδες αρχείων.

4.3.1 Η Γλώσσα Gremlin

Η γλώσσα ερωτημάτωνGremlinη οποία υποστηρίζεται από αρκετές βάσεις δεδομένων γράφων χρησιμοποιείται και στη Cayley, για να ανακτηθούν αλλά και να τροποποιηθούν τα δεδομένα του γράφου. Ουσιαστικά, η Gremlineίναι μια γλώσσα η οποία εκφράζει τις σύνθετες διαδρομές των γράφων.

Έχει σχεδιαστεί για να αποθηκεύει τα δεδομένα σαν ζεύγος κλειδί – τιμή, αναλύει και να χειρίζεται, κατευθυνόμενες και πολλαπλές σχέσεις στους γράφους της. Οι λειτουργίες της Gremlinαναφέρονται παρακάτω και είναι:

- Με τον όρο κλειδί – τιμή αναφέρεται στο γεγονός ότι οι 2 κορυφές και οι άκρες τους μπορούν ανάμεσα τους να έχουν οποιοδήποτε αριθμό ιδιοτήτων.
- Ο όρος κατευθυνόμενος αναφέρεται στο γεγονός ότι οι σχέσεις του γράφου έχουν κατευθυντικότητα.
- Τέλος, με τον όρο πολλαπλές αναφέρεται στο γεγονός ότι μπορεί να υπάρχουν πολλοί τύποι ακμών, έτσι δημιουργούνται πολλές μεταξύ των κορυφών.

Στην Εικόνα 11 που ακολουθεί εμφανίζεται ένας Γράφος ιδιοτήτων οποίος περιέχει σαν στοιχεία περιέχει ένα σύνολο κόμβων και ένα σύνολο ακμών.

Κάθε σύνολο κόμβων διαθέτει ένα μοναδικό αναγνωριστικό. Επίσης, κάθε κόμβος έχει ένα σύνολο εξερχόμενων άκρων αλλά και ένα σύνολο εισερχόμενων άκρων. Ενώ, κάθε κόμβος έχει μια συλλογή ιδιοτήτων που ορίζεται από έναν χάρτη από το κλειδί στην τιμή.

Το σύνολο των άκρων διαθέτουν σαν χαρακτηριστικά τα έξης κάθε άκρη έχει ένα μοναδικό αναγνωριστικό, κάθε άκρη έχει μια εξερχόμενη κορυφή στο πίσω μέρος και μια εισερχόμενη κορυφή κεφαλής. Ακόμα, κάθε άκρη έχει μια ετικέτα που υποδηλώνει τον τύπο της σχέσης μεταξύ των δύο κορυφών της. Τέλος, κάθε άκρη έχει μια συλλογή ιδιοτήτων που ορίζεται από έναν χάρτη από το κλειδί στην τιμή.

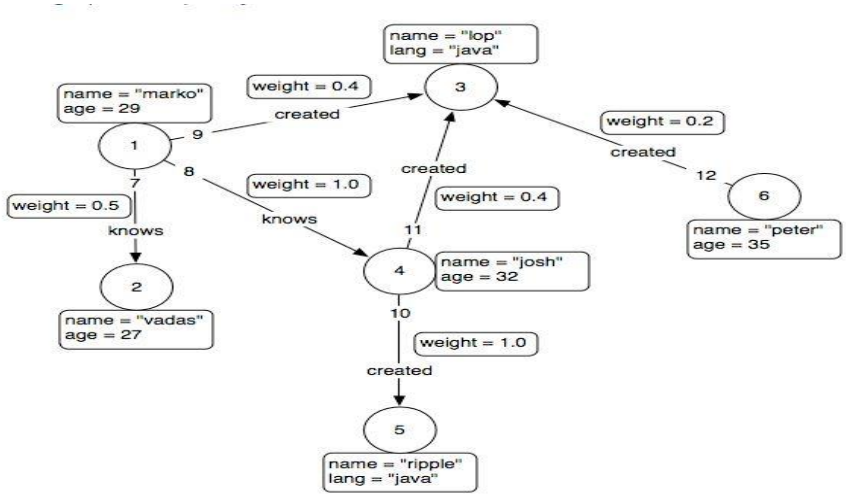

Εικόνα 11 – Απεικόνιση γράφου

4.3.2Πλεονεκτήματα της Gremlin

Πριν εμβαθύνουμε στα ιδιαίτερα χαρακτηριστικά της Gremlin, είναι καλό να δούμε μερικούς λόγους για τους οποίους αξίζει να την χρησιμοποιήσουμε.

Η Gremlin είναι χρήσιμη για να δουλεύουμε σε γραφήματα: Μπορούμε να περιηγούμαστε στο γράφημα, να κάνουμε ανανέωση ιδιοτήτων στους κόμβους, να προσθέτουμε ακμές, να αφαιρούμε κόμβους, κτλπ. Η Gremlin είναι ιδανική για την διαχείριση του γραφήματος και την διασφάλιση της ακεραιότητας των δεδομένων. Δεν υπάρχει τίποτα χειρότερο από το να συνειδητοποιήσουμε ότι δεν είναι ο κωδικός, αλλά τα δεδομένα που περιέχουν σφάλματα.

Η Gremlin επιτρέπει την δημιουργία ερωτημάτων γραφημάτων: Καθώς δουλεύετε με την Gremlin, θα παρατηρήσετε ότι πολλά είδη ερωτημάτων μπορούν να εκφραστούν με πολύ πιο συνοπτικό και κατανοητό τρόπο από ότι με τις παραδοσιακές γλώσσες προγραμματισμού. Εάν αναπτύσσετε μια εφαρμογή που απαιτεί ένα ερώτημα γραφήματος, τότε ίσως είναι καλύτερο να χρησιμοποιήσετε την Gremlin.

Η Gremlin μπορεί να εκφράσει συνοπτικά περίπλοκες διαδρομές γραφημάτων: Η Gremlin μπορεί να εκφράσει σε μερικές γραμμές κώδικα κάτι που θα απαιτούσε πολύ περισσότερες γραμμές σε κώδικα Java. Επιπλέον, η Gremlin σχεδιάστηκε για να αναπαριστά περίπλοκες διαδρομές γραφημάτων. Ακόμη και οι σημερινές βάσεις δεδομένων γραφημάτων δεν έχουν την δυνατότητα να εκφράζουν περίπλοκες διαδρομές γραφημάτων - κάτι που η Gremlin μπορεί να κάνει πολύ κομψά.

Η Gremlin είναι χρήσιμη για να εξερεύνηση και εκμάθηση σχετικά με γραφήματα: Υπάρχουν πολλά πρόσθετα / συνδέσεις για την Gremlin που το καθιστούν ένα μοναδικό περιβάλλον για να παίζετε με γραφήματα.

Η Gremlin επιτρέπει την εξερεύνηση του Σημασιολογικού Ιστού / Ιστό Δεδομένων: Η Gremlin μπορεί να χρησιμοποιηθεί με γραφήματα RDF. Επιπλέον, η Gremlin διαθέτει ένα σύνδεσμο για το LinkedData Sail το οποίο σας επιτρέπει να εργάζεστε με τον Σημασιολογικό Ιστό / Ιστός Δεδομένων σε πραγματικό χρόνο.

Η Gremlin δεν είναι συνδεδεμένη με ένα συγκεκριμένο backend γραφημάτων: η Gremlin μπορεί να χρησιμοποιηθεί με διάφορες βάσεις δεδομένων γραφημάτων. Έτσι, μπορείτε να χρησιμοποιήσετε τον ίδιο κώδικα Gremlin ακόμα και όταν αλλάζετε το backend της βάσης δεδομένων.

Η Gremlin επιτρέπει υπολογισμούς με βάση την διαδρομή (path-based): Η Gremlin σάς επιτρέπει να ελέγχετε, στο μέγιστο βαθμό, την εκτέλεση μιας διαδρομής μέσα σε ένα γράφημα. Αυτό παρέχει την ευελιξία να δημιουργήσετε εξελιγμένους τρόπους με τους οποίους μπορείτε να αναλύσετε, να αναζητήσετε και να επεξεργαστείτε ένα γράφημα.

Η Gremlin είναι επεκτάσιμη και μπορεί να προσαρμοστεί σε κάθε συγκεκριμένη περίπτωσή: Είναι δυνατό να επεκτείνετε την Gremlin με νέες μεθόδους και βήματα που έχουν καθοριστεί εγγενώς στη Gremlin ή στην Java. Επιπλέον, είναι δυνατό να προσθέσετε άλλες βάσεις δεδομένων γραφημάτων, υλοποιώντας τις διεπαφές που παρέχονται από τα πρότυπα.

Η Gremlin χρησιμοποιεί το Java API: Η εικονική μηχανή για την Gremlin είναι η εικονική μηχανή Java. Ο κώδικας Gremlin μπορεί να επωφεληθεί από το Java API. Με αυτόν τον τρόπο, η Gremlin και η Java λειτουργούν άψογα μαζί.

Η Gremlin είναι ενσωματωμένο σε διάφορες γλώσσες JVM: Ο πυρήνας της Gremlin είναι γραμμένος σε Java. Ωστόσο, η Gremlin διανέμετε με κατασκευές για τη γλώσσα Groovy. Με αυτόν τον τρόπο, η Gremlin είναι περισσότερο ένας τρόπος περιγραφής διαδρομών πέρα από μια γλώσσα, που άλλες γλώσσες JVM μπορούν φυσικά να φιλοξενήσουν.

Η Gremlin είναι ο Turing πλήρης: Πολλές γλώσσες διαδρομών γραφημάτων μπορούν να αναγνωρίσουν μόνο τα κανονικά μονοπάτια μέσα σε ένα γράφημα. Η Gremlin παρέχει πολυάριθμες κατασκευές μνήμης και υπολογιστών για την υποστήριξη αυθαίρετης αναγνώρισης του μονοπατιού.

4.4Δημιουργία ερωτημάτων στην Gremlin

Η χρήση της γλώσσας ερωτημάτων Gremlin χρησιμοποιείται για ερωτήματα, ανάλυση αλλά και χειρισμό των δεδομένων. Ένα ερώτημα Gremlin πρόκειται για μια αλυσίδα λειτουργιών οι οποίες αξιολογούνται από αριστερά προς τα δεξιά.

Εισάγονται οι έννοιες για την λειτουργία των ερωτημάτων στους γράφους. Υπάρχει δυνατότητα επιλογής ενός ή περισσότερων κόμβων οπού με την χρήση της γλώσσας Gremlinθα διασχιστεί ο γράφος. Παρακάτω παρουσιάζονται τα βασικά στοιχεία για την σύνταξη της γλώσσας Gremlin, τα οποία θα βασιστούν στον γράφο της Εικόνας 12.

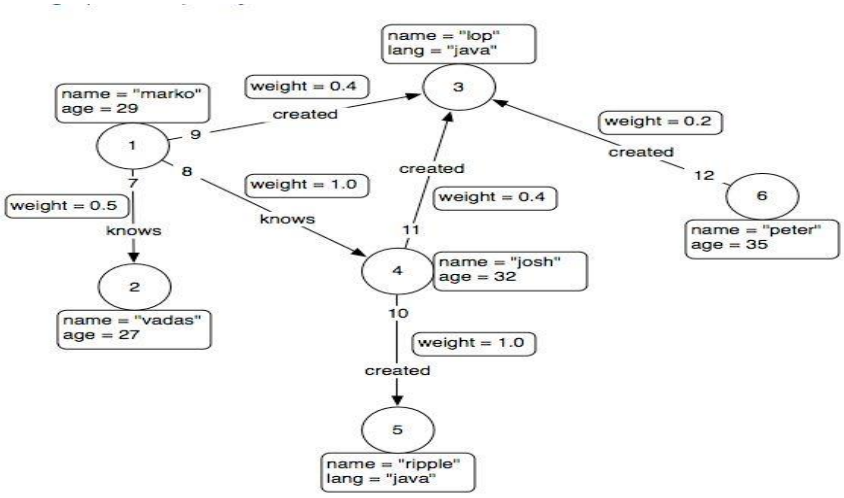

Εικόνα 12- Απεικόνιση γράφου

Στοιχείο V

Το στοιχείο Vχρησιμοποιείται για να επαναλάβει όλους τους κόμβους του γράφου, με μια συγκριμένη ιδιότητα την οποία ορίζουμε.

```
gremlin> g.V("name", "marko")
==>v[1]
```

Όπως φαίνεται και στην Εικόνα απεικόνισης του γράφου, στο παραπάνω παράδειγμα ζητείται σαν ερώτημα να επιστραφούν όσοι κόμβοι έχουν σαν ιδιότητα το όνομα marko, οπότε το αποτέλεσμα του ερωτήματος είναι ο κόμβος 1.

Στοιχείο E

Το στοιχείο E διατρέχει όλες τις ακμές του γράφου. Χρησιμοποιείτε για να διατρέξει όλες τις ακμές του γράφου ωστόσο στους μεγάλους γράφους χρησιμοποιείτε με προσοχή.

```
Gremlin> g.E
==>e[10][4-created->5]
==>e[7][1-knows->2]
==>e[9][1-created->3]
==>e[8][1-knows->4]
==>e[11][4-created->3]
==>e[12][6-created->3]
```

Όπως φαίνεται και στο παραπάνω παράδειγμα το στοιχείο E διατρέχει όλους τους κόμβους του γράφου και αποτυπώνει την ιδιότητα που υφίσταται ανάμεσα σε 2 κόμβους είτε από αριστερά προς στα δεξιά είτε από δεξιά προς τα αριστερά. Για παράδειγμα, ανάμεσα στους κόμβους 1 και 2 υπάρχει η ιδιότητα “created”, ενώ ο κόμβος διασχίζεται από τα αριστερά προς τα δεξιά. Επίσης, ο κόμβος 6 και ο κόμβος 3 διασχίζονται από δεξιά προς τα αριστερά έχοντας την ιδιότητα “created”.

Στοιχείο id

Το στοιχείο id επιστρέφει τη μοναδική ταυτότητα του στοιχείου.

```
gremlin> v = g.V("name", "marko").next()
==>v[1]
```

Στο παραπάνω παράδειγμα τίθεται σαν ερώτημα στον γράφο να επιστρέψει το όνομα του κόμβου με όνομα macro, επομένως υπάρχει ένας και μοναδικός κόμβος με αυτήν την ταυτότητα και αυτός είναι ο κόμβος 1.

Στοιχείο in

Επιστρέφει τους γειτονικούς κόμβους του συγκεκριμένου κόμβου, διασχίζοντας τους κόμβους από το τέλος προς την αρχή, δηλαδή από τα δεξιά προς τα αριστερά.

```
gremlin> v.in("created")
==>v[1]
==>v[4]
==>v[6]
```

Χρησιμοποιώντας την Εικόνα12 η οποία απεικονίζει τον γράφο και γνωρίζοντας ότι το στοιχείο in επιστρέφει τους γειτονικούς κόμβους, τότε στο παραπάνω παράδειγμα το οποίο θέτει σαν ερώτημα να επιστραφούν όσοι κόμβοι διαθέτουν την ιδιότητα “created”, διασχίζοντας τους κόμβους από το τέλος στην αρχή η απάντηση του ερωτήματος θα αφορά τους κόμβους 1, 4 και 6.

Στοιχείο order

Ταξινομεί τα αντικείμενα με βάση την συνάρτηση που ορίζει ο χρήστης. Αν δε δοθεί συνάρτηση, χρησιμοποιείται η βασική σειρά στη ταξινόμηση.

```
gremlin> g.V.name.order
==>josh
==>lop
==>marko
==>peter
==>ripple
==>vadas
```

Το παραπάνω παράδειγμα περιγράφει την ταξινόμηση των κόμβων θέτοντας σαν κριτήριο ταξινόμησης το όνομα τους, το αποτέλεσμα το οποίο προκύπτει η αλφαβητική και αύξουσα ταξινόμηση των κόμβων σύμφωνα με το όνομα το οποίο διαθέτει ο καθένας.

Στοιχείο out

Επιστρέφει τους εξερχόμενους γειτονικούς κόμβους του συγκεκριμένου κόμβου, διασχίζοντας τους κόμβους από την αρχή προς το τέλος, δηλαδή από τα αριστερά προς τα δεξιά.

```
gremlin> v.out('knows')
==>v[2]
==>v[4]
```

Επομένως στο παραπάνω παράδειγμα και κάνοντας χρήση της Εικόνας 12, το ερώτημα το οποίο τίθεται στον γράφο είναι να επιστρέψει όλους τους κόμβους οι οποίοι διαθέτουν την ιδιότητα “knows”. Το αποτέλεσμα του γράφου στο ερώτημα είναι ότι την ιδιότητα “knows” έχουν ο κόμβος 2 και ο κόμβος 4.

Στοιχείο outE

Επιστρέφει τις εξερχόμενες ακμές του συγκεκριμένου κόμβου.

```
gremlin> v.outE
==>e[7][1-knows->2]
==>e[8][1-knows->4]
==>e[9][1-created->3]
```

Στο παραπάνω παράδειγμα, κάνοντας χρήση του στοιχείου outE για το ερώτημα αλλά και της Εικόνας 12, παρατηρείται ότι το αποτέλεσμα του γράφου στο ερώτημα είναι ότι η επιστροφή όλων των ακμών για τον κόμβο 1. Έτσι το αποτέλεσμα του γράφου σε αυτό το ερώτημα να επιστραφούν οι ακμές και οι ιδιότητες τους για τον κόμβο 1, πιο συγκεκριμένα παρατηρείται ότι ο κόμβος 1 έχει σχέση με τον κόμβο 2 και διαθέτουν την ιδιότητα knows, ο κόμβος 1 με τον κόμβο 4 διαθέτουν επίσης την ιδιότητα knows και ο κόμβος 1 με τον κόμβο 3 διαθέτουν την ιδιότητα created.

Στοιχείο outV

Επιστρέφει τον εξερχόμενο κόμβο τις συγκεκριμένης ακμής.

```
gremlin> e = g.e(12)
==>e[12][6-created->3]
gremlin> e.outV
==>v[6]
```

Σχετικά με το στοιχείο outV, στο παραπάνω παράδειγμα παρατηρείται ότι τίθεται σαν ερώτημα ποιος κόμβος διαθέτει την σχέση 12 και το αποτέλεσμα το οποίο

λαμβάνεται είναι ότι η ιδιότητα 12 είναι ανάμεσα στους κόμβους 6 και 3, με εξερχόμενο κόμβο τον 3.

Στοιχείο has

Επιλέγει ένα στοιχείο αν έχει μια συγκεκριμένη ιδιότητα. Χρησιμοποιεί διάφορες επιλογές για σύγκριση μέσω του T, οι επιλογές που μπορούν να χρησιμοποιηθούν αναφέρονται παρακάτω.

- T.gt - greater than (μεγαλύτερο από)
- T.gte - greater than or equal to (μεγαλύτερο ή ίσο από)
- T.eq - equal to (ίσο με)
- T.neq - not equal to (διάφορο από)
- T.lte - less than or equal to (μικρότερο ή ίσο από)
- T.lt - less than (μικρότερο από)
- T.in - contained in a list (περιέχεται στην λίστα)
- T.notin - not contained in a list (δεν περιέχεται στην λίστα)

Αξίζει να επισημάνουμε ότι η σύνταξη του has είναι αντίστοιχη με την g.V("name", "marko"), με την διαφορά ότι είναι μια αναζήτηση σε index κλειδί με αποτέλεσμα να είναι γρήγορη. Σε αντίθεση η εντολή g.V.has("name", "marko") , θα διατρέξει όλους τους κόμβους ελέγχοντας για την ιδιότητα name σε κάθε κόμβο και θα είναι πολύ πιο αργή.

Η συμπεριφορά του has έχει να κάνει με την υλοποίηση της στο σύστημα και τα παραπάνω ισχύουν στα περισσότερα συστήματα. Για παράδειγμα, η Cayley θα προσπαθήσει να χρησιμοποιήσει index οπουδήποτε μπορεί να το κάνει. Δηλαδή είναι

σημαντικό να καταλάβουμε την υλοποίηση του κάθε συστήματος όταν γράφουμε ερωτήματα.

```
gremlin> g.v(1).outE.has("weight", T.gte, 0.5f).weight
==>0.5
==>1.0
gremlin> g.V.has('age').name
==>vadas
==>marko
==>peter
==>josh
```

Αρχικά στο πρώτο παράδειγμα της ιδιότητας has, ζητείται σαν ερώτημα να επιστρέφει τις εξερχόμενες ακμές του κόμβου 1 οι οποίες διαθέτουν βάρος μεγαλύτερο ή ίσο με 0,5f, έτσι διασχίζεται ολόκληρος ο γράφος και δίνει σαν αποτέλεσμα τους κόμβους με βάρος 0,5 και 1.0.

Στο δεύτερο παράδειγμα του στοιχείου has, τίθεται σαν ερώτημα να εμφανίσει όσους κόμβους αναγράφουν μαζί με το όνομα και την ηλικία τους, επομένως το ερώτημα θα διασχίσει όλους τους κόμβους και θα επιστρέψει όσους διαθέτουν όνομα και ηλικία που στην προκειμένη περίπτωση είναι οι κόμβοι με όνομα vadas, marko, peter και josh.

5. Η Εφαρμογή μας

5.1 Αρχιτεκτονική

Στα πλαίσια της εφαρμογής μας ως πηγή αρχείου θα χρησιμοποιηθεί μια βάση δεδομένων γράφων η οποία περιγράφει ένα υποθετικό γενεαλογικό δέντρο.

Συγκεκριμένα, το αρχείο το οποίο θα δημιουργήσουμε θα έχει την μορφή τετράδων (N-quads) απλού κείμενου όπου στο κείμενο αυτό θα περιγράφεται ο γράφος ενός οικογενειακού δέντρου. Επίσης, αυτή η κωδικοποίηση χρησιμοποιείται για την κωδικοποίηση ενός συνόλου δεδομένων RDF.

Η μορφή των τετράδων (N-quads)αποτελεί επέκταση των τριπλέτων (N-triples), με την κύρια διαφορά των τετράδων είναι στο ότι επιτρέπουν την κωδικοποιήση πολλαπλών γράφων. Το οικογενειακό δέντρο περιγράφεται στην επόμενη ενότητα.

5.2 Σενάριο Χρήσης Εφαρμογής

Για την απεικόνιση των δεδομένων δημιουργήθηκε μια τετράδα χρησιμοποιώντας τα ονόματα και τις σχέσεις των μελών της οικογένειας, και στη συνέχεια δημιουργούμε ένα αρχείο με όνομα 'familytree.nq'. Η απεικόνιση των δεδομένων παρουσιάζεται παρακάτω στον Πίνακα 8.

Το οικογενειακό δέντρο το οποίο δημιουργήθηκε και θα υπάρξει απεικόνιση μέσω γράφων, στην βάση Cayley αφορά 2 αδέλφια, η Γεωργία και ο Γιάννης. Πιο συγκεκριμένα, η Γεωργία γεννήθηκε το 1954 και ο Γιάννης το 1956. Η Γεωργία μένει στην Μεγαλόπολη και είναι παντρεμένη με τον Κώστα Μπαρέκα ο οποίος έχει γεννηθεί το 1950. Η Γεωργία έχει 3 παιδιά τον Βασίλη που γεννήθηκε το 1979, τον Στάθη που γεννήθηκε το 1979 και την Μαρία που γεννήθηκε το 1988.Με την σειρά του, ο Γιάννης έχει το επίθετο Οικονόμου, μένει στην Κόρινθο και είναι παντρεμένος με την Άννα η οποία γεννήθηκε το 1960. Έχουν 2 παιδιά τον Γεώργιο που γεννήθηκε το 1980 και την Λίζα που γεννήθηκε το 1985.

Τώρα, ο Βασίλης μένει στην Πάτρα, είναι παντρεμένος με την Αμαλία η οποία γεννήθηκε το 1980 και έχουν 2 παιδία τον Κωνσταντίνο που γεννήθηκε το 2013 και την Όλγα που γεννήθηκε το 2017. Η Αμαλία έχει μια αδελφή δίδυμη την Τίνα Χαρίση η οποία μένει στην Άρτα και γεννήθηκε το 1984. Ο Στάθης μένει στην Αθήνα είναι παντρεμένος με την Ελένη που γεννήθηκε το 1986 και έχουν 2 παιδία, τον Φίλιππο που γεννήθηκε το 2012 και τον Πέτρο που γεννήθηκε το 2014. Η Ελένη έχει έναν αδελφό με το όνομα Νίκος Πέτρου που μένει στην Αθήνα και γεννήθηκε το 1983. Η Μαρία μένει στην Καλαμάτα, είναι παντρεμένη με τον Δημήτρη που έχει γεννηθεί το 1982 και έχουν ένα παιδί τον Ανδρέα που έχει γεννηθεί το 2016. Ο Δημήτρης έχει 2 αδέλφια τον Βασίλη και τον Τέλη που έχουν γεννηθεί το 1987 και το 1993, αντίστοιχα και μένουν και οι 2 στην Καλαμάτα.

Ο Γιώργος μένει στην Αθήνα, παντρεύτηκε την Χριστίνα που είναι γεννημένη το 1983 και έχουν ένα παιδί με όνομα Κατερίνα που έχει γεννηθεί το 2015. Η Λίζα μένει στην Θεσσαλονίκη είναι παντρεμένη με τον Απόστολο Νίκου που έχει γεννηθεί το 1978 και δεν έχουν παιδία.

```
"georgia" "name" "Georgia Barekas" .

"georgia"  "born" "1954" .

"georgia" "lives" "Megalopolis" .

"john" "name" "John Oikonomou" .

"john" "born" "1956" .

"john" "lives" "Korinthos" .

"georgia" "sibling" "john" .

"kostas" "name" "Kostas Barekas" .

"kostas" "born" "1950" .

"anna" "name" "Anna Oikonomou" .
```

```
"anna" "born" "1960" .

"bill" "name" "Bill Barekas" .

"bill"  "born" "1975" .

"steve" "name" "Steve Barekas" .

"steve" "born" "1979" .

"maria" "name" "Maria Barekas" .

"george" "name" "George Oikonomou" .

"george" "born" "1980" .

"liza" "name" "Liza Oikonomou" .

"liza" "born" "1960" .

"amalia" "name" "Amalia Barekas" .

"amalia" "born" "1982" .

"konstantinos" "name" "Konstantinos Barekas" .

"konstantinos" "born" "2013" .

"olga" "name" "Olga Barekas" .

"olga" "born" "2017" .

"tina" "name" "Tina Charisis" .

"tina" "born" "1982" .

"tina" "lives" "Artas" .

"helen" "name" "Helen Barekas" .

"helen" "born" "1986" .
```

```
"filippos" "name" "Filippos Barekas" .

"filippos" "born" "2012" .

"petros" "name" "Petros Barekas" .

"petros" "born" "2014" .

"nikos" "name" "Nikos Petrou" .

"nikos" "born" "1983" .

"nikos" "lives" "Athens" .

"jim" "name" "Jim Karlis" .

"jim" "born" "1982" .

"basilis" "name" "Basilis Karlis" .

"basilis" "born" "1987" .

"basilis" "lives" "Kalamatas" .

"telis" "name" "Telis Karlis" .

"telis" "born" "1993" .

"telis" "lives" "Tripolis" .

"andreas" "name" "Andreas Karlis" .

"andreas" "born" "2016" .

"christina" "name" "Christina Oikonomou" .

"christina" "born" "1983" .

"kathrin" "name" "Kathrin Oikonomou" .

"kathrin" "born" "2015" .
```

```
"apostolis" "name" "Apostolis Nikou" .

"apostolic" "born" "1978" .

"bill" "lives" "Patras" .

"steve" "lives" "Athens" .

"maria" "lives" "Kalamatas" .

"george" "lives" "Athens" .

"liza" "lives" "Thesallonikis" .

"georgia" "spouse" "kostas" .

"georgia" "child" "bill" .

"georgia" "child" "steve" .

"georgia" "child" "maria" .

"john" "spouse" "anna" .

"john" "child" "george"  .

"john" "child" "liza" .

"bill" "spouse" "amalia" .

"bill" "child" "konstantinos" .

"bill" "child" "olga" .

"steve" "spouse" "helen" .

"steve" "child" "filippos" .

"steve" "child" "petros" .

"maria" "spouse" "jim" .
```

"maria" "child" "andreas" .

"george" "spouse" "christina" .

"george" "child" "kathrin" .

"liza" "spouse" "apostolis" .

"bill" "brother" "steve" .

"bill" "sibling" "maria" .

"steve" "sibling" "maria" .

"george" "sibling" "liza" .

"tina" "sibling" "amalia" .

"nikos" "sibling" "helen" .

"basilis" "brother" "jim" .

"telis" "brother" "jim" .

Πίνακας 8–Δεδομένα Σεναρίου Χρήσης Εφαρμογής

5.3 Μεταφόρτωση αρχείου στη Cayley

Μετά την δημιουργία του αρχείο με όνομα 'familytree.nq', το οποίο περιέχει τετράδες ενός οικογενειακού δέντρου, θα πρέπει να το προσθέσουμε στη βάση δεδομένων γράφων Cayley. Τώρα, προκείμενου δημιουργηθούν ερωτήματα και να απαντηθούν θα πρέπει να μεταφορτωθεί το αρχείο που δημιουργήθηκε μέσα στη Cayley.

Η διαδικασία της μεταφόρτωσης αρχικά απαιτεί το άνοιγμα της γραμμής εντολών και στην συνέχεια πληκτρολογείτε η εντολή **.\cayley.exe http --dbpath="familytree.nq"**, όπως φαίνεται και στην Εικόνα 13.

Εικόνα 13 – Μεταφόρτωση Βάσης Γράφου στην Cayley

Εμφανίζεται, μια διεύθυνση, στην προκείμενη περίπτωση είναι η 127.0.0.1:64210, την οποία θα ανοίξουμε σε ένα browserκαι θα εμφανίσει τη βάση που αφορά το οικογενειακό δέντρο που δημιουργήσαμε. Στην συνέχεια, με την δημιουργία των κατάλληλων ερωτημάτων, η βάση δεδομένων γράφων για το οικογενειακό δέντρο, θα επιστρέφει σαν αποτέλεσμα αυτά τα οποία ερωτούνται.

5.4 Δημιουργία Ερωτημάτων

Για την δημιουργία ερωτημάτων στην εφαρμογή μας χρησιμοποιείται η γλώσσα Gremlin, οπού παραπάνω έχουν αναφερθεί τα χαρακτηριστικά της, υπάρχει δυνατότητα δημιουργίας ερωτημάτων είτε μέσω του πεδίου ερωτήματος(query) είτε μέσω του πεδίου της απεικόνιση ερωτημάτων (visualize). Επομένως, θα περιγράφετε το κάθε ερώτημα, η σύνταξη του καθώς και το αποτέλεσμα του κάθε ερωτήματος το οποίο θα προκύπτει είτε μέσα από το πεδίο queryείτε από το πεδίοvisualize.

5.4.1 Δημιουργία Ερωτημάτων στο πεδίο query

Το πρώτο ερώτημα το οποίο θα αφορά όλα τα παιδία της Γεωργίας, επομένως θα διασχίσει τους κόμβους από την αρχή προς το τέλος χρησιμοποιώντας το στοιχείοout και θα εμφανίσει όλα τα άτομα με την ιδιότητα “child” θα δημιουργηθεί στο πεδίο querykαι θα έχει σύνταξη**: g.V("georgia").Out("child").All(),** το αποτέλεσμα της Cayley εμφανίζεται στην Εικόνα 14.

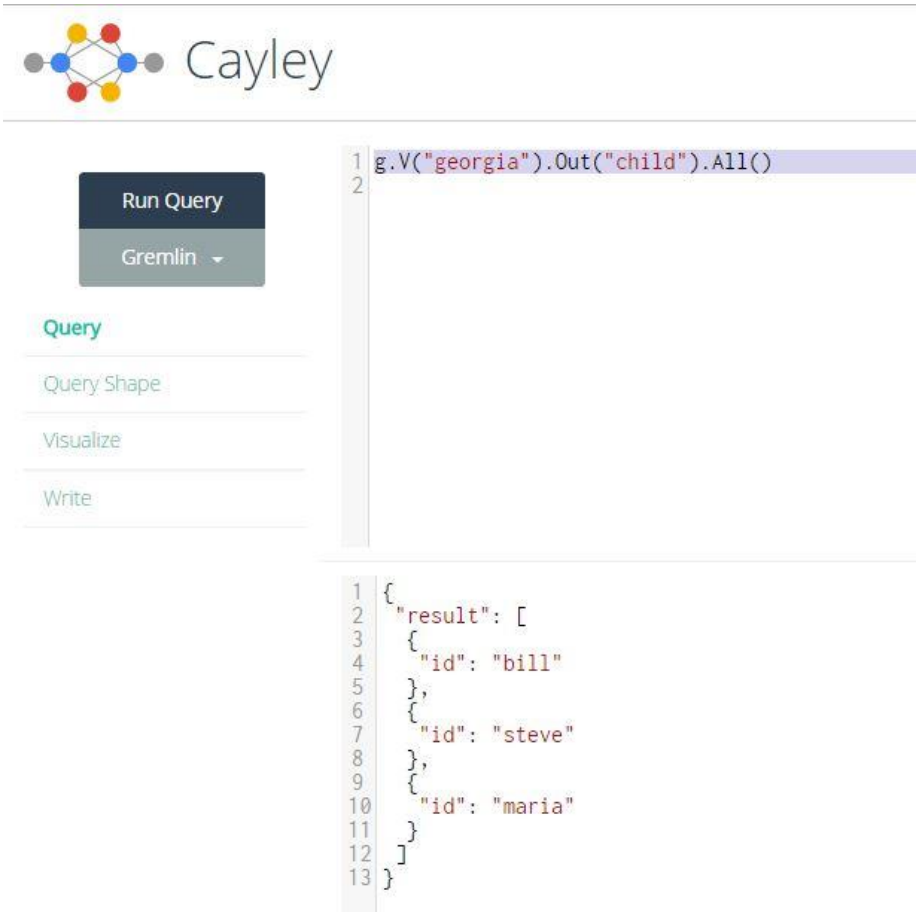

Εικόνα 14 – Αποτελέσματα Ερωτήματος που εμφανίζει όλα τα παιδία της Γεωργίας

Το επόμενο ερώτημα το οποίο θέτουμε στην βάση είναι να μας επιστρέψει όλα τα άτομα τα οποία έχουν γεννηθεί το 1982, επομένως θα χρησιμοποιηθεί το στοιχείο in, αφού θα πρέπει να διασχίζει τους κόμβους από το τέλος προς την αρχή. Το ερώτημα το οποίο θα γράψουμε στο πεδίο queryθα έχει σύνταξη: **g.V("1982").In("born").All().**Το αποτέλεσμα της Cayley παρουσιάζεται στην Εικόνα 15.

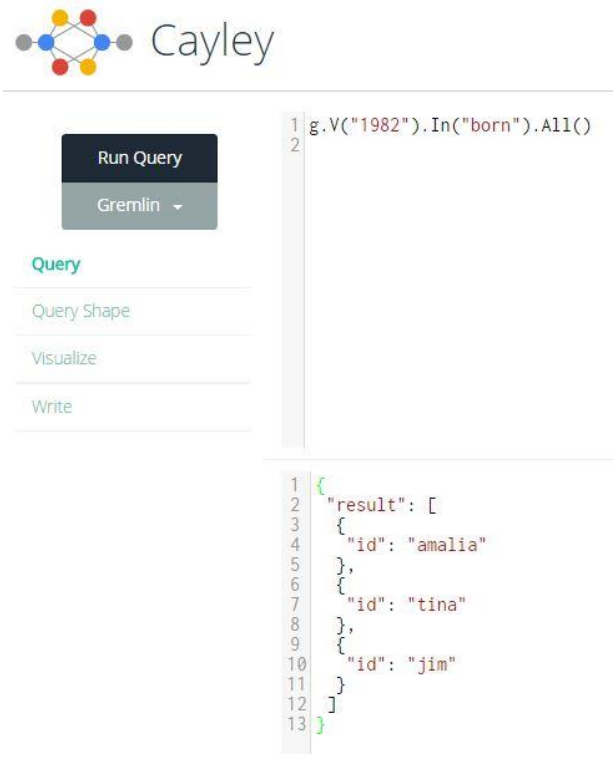

Εικόνα 15 – Αποτέλεσμα Ερωτήματος όσων έχουν γεννηθεί το 1982

Το τελευταίο ερώτημα το οποίο θέτουμε στην βάση είναι να επιστρέψει το έτος γέννησης των παιδιών του Βασίλη, επομένως θα χρησιμοποιηθεί το στοιχείο out τόσο για την ιδιότητα "παιδί" όσο και για την ιδιότητα "γέννησης" και θα πρέπει να διασχίζει τους κόμβους από την αρχή προς την τέλος. Το ερώτημα το οποίο θα γράψουμε στο πεδίο query θα έχει σύνταξη: **g.V("bill").Out("child").Out("born").All()**

Το αποτέλεσμα της Cayley παρουσιάζεται στην Εικόνα 16.

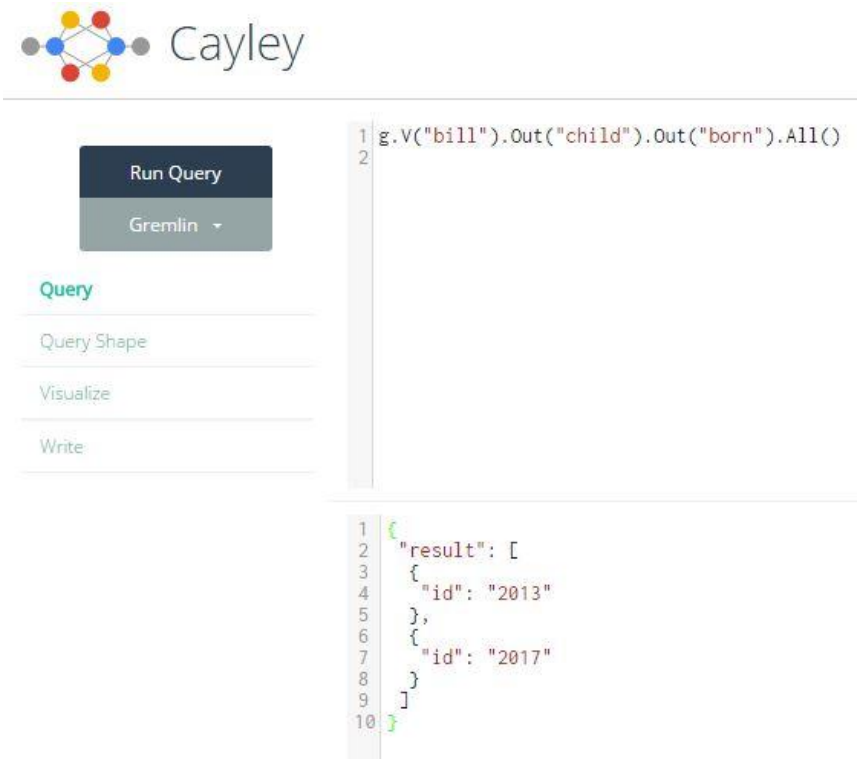

Εικόνα 16 –Εμφάνιση Ερωτήματος του έτος γέννησης των παιδιών του Βασίλη

5.4.2 Δημιουργία Ερωτημάτων στο πεδίο Visualize

Τα ερωτήματα στο πεδίο Visualize (απεικόνιση) ανιχνεύει τους κόμβους είτε ως "πηγή" είτε ως "στόχο". Η πηγή θα αντιπροσωπεύεται ως μπλε κόμβος και ο στόχος θα αντιπροσωπεύεται ως πορτοκαλί κόμβος. Ενώ, η σύνταξη η οποία χρησιμοποιείται είναι διαφορετική από το πεδίο query, αφού γίνεται χρήση του στοιχείου asπροκείμενου να ονομάσει το προηγούμενο βήμα. Παρακάτω περιγράφονται τα ερωτήματα απεικόνισης που πραγματοποιήθηκαν στην Cayley.

Αρχικά, το πρώτα ερώτημα απεικονίζει τα παιδιά της Γεωργίας και τα ονόματα αυτών, η σύνταξη του ερωτήματος είναι η εξής:

g.V("georgia").Save("name","source").As("source").Out("child", "relation").Save("name","target").As("target").All()

Αρχικά, ορίζεται ο κόμβος με το όνομα της Γεωργίας, στην συνέχεια αποθηκεύεται το όνομα ως πηγή, έπειτα θα ζητείται να εμφανιστούν οι εξερχόμενοι κόμβοι οι οποίοι έχουν την σχέση παιδί και τέλος αποθηκεύονται σαν στόχος, οπού προκύπτει και το αποτέλεσμα της Εικόνας 17.

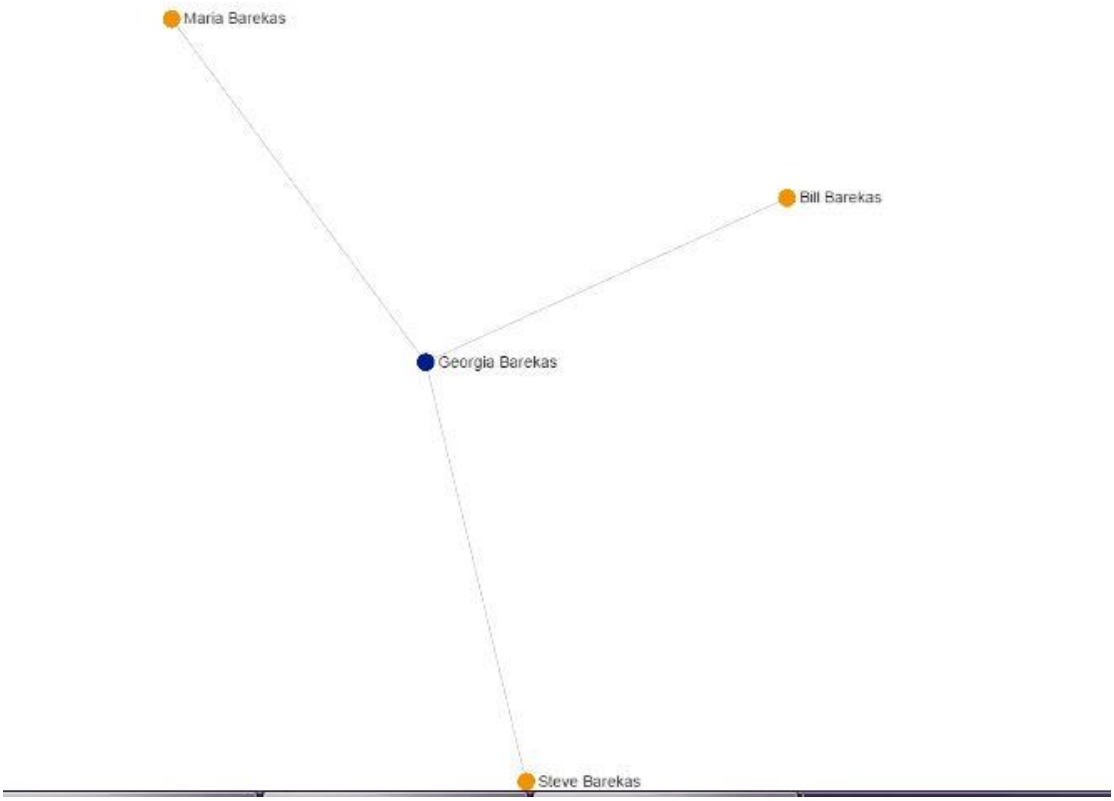

Εικόνα 17 –Οι Κόμβοι των παιδιών της Γεωργίας

Το επόμενο ερώτημα θα παρουσιάζει τον άντρα, τον αδελφό και τα παιδία της Γεωργίας, η σύνταξη του ερωτήματος έχει την μορφή

g.V("georgia").Save("name","source").As("source").Out(["child","spouse", "sibling"], "relation").Save("name","target").As("target").All()

Επομένως, η σύνταξη του ερωτήματος ορίζει αρχικά τον κόμβο με το όνομα της Γεωργίας, τον αποθηκεύει με το όνομα του σαν πηγή έτσι ώστε να υπάρχει η οπτικόποιηση του και στην συνέχεια ζητά τους εξερχόμενους κόμβους με ιδιότητα παιδί, αδελφού και άντρα και τους αποθηκεύει το όνομα τους σαν στόχο.

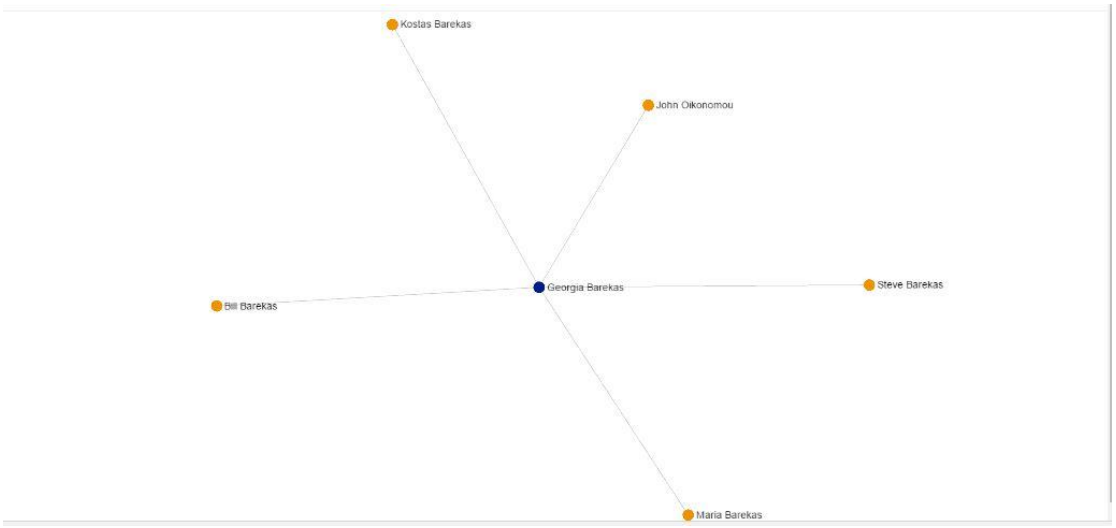

Εικόνα 18 – Οι κόμβοι εμφανίζουν τον άντρα, τον αδελφό και τα παιδία της Γεωργίας

Το επόμενο ερώτημα θα εμφανίζει τα εγγόνια της Γεωργίας, έχοντας σύνταξη**g.V("georgia").Save("name","source").As("source").Out("child", "relation").Out("child", "relation").Save("name","target").As("target").All(),** το αποτέλεσμα του ερωτήματος εμφανίζεται στη Εικόνα 19.

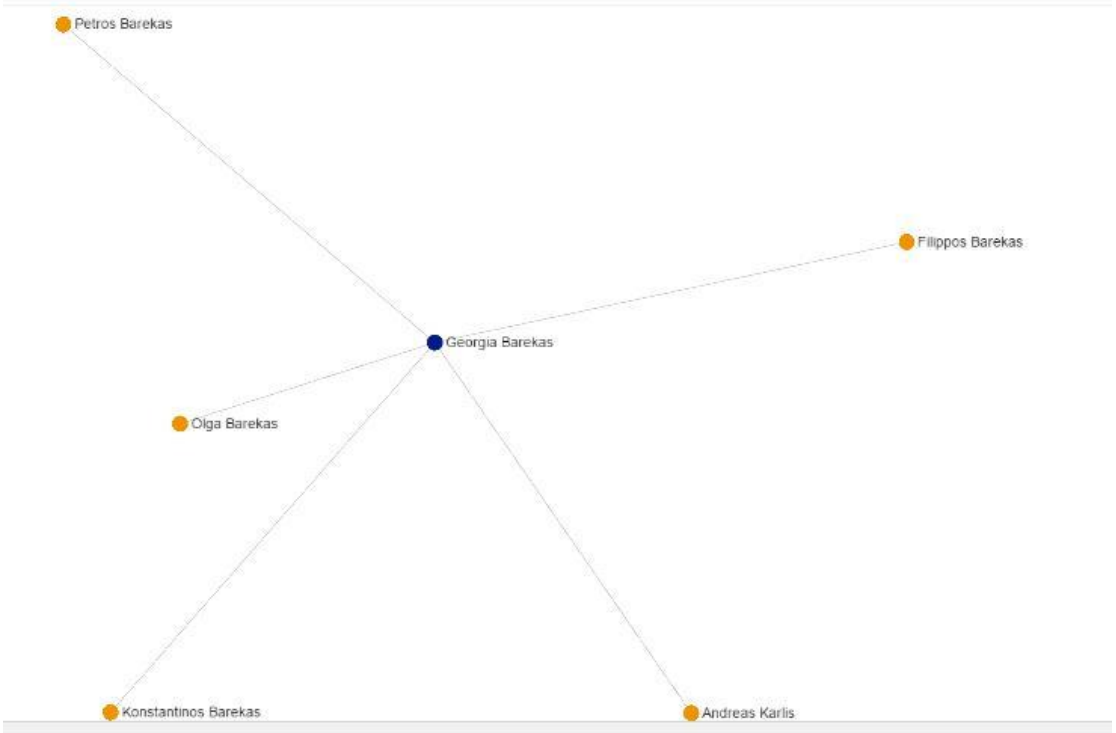

Εικόνα 19 – Οι κόμβοι των εγγονιών της Γεωργίας

Επομένως, το παραπάνω ερώτημα ορίζει τον κόμβο της Γεωργίας, τον αποθηκεύει με το όνομα του σαν πηγή προκειμένου να υπάρξει απεικόνιση και στην συνεχεία ζητάει να εμφανιστούν με το στοιχείο out όλοι εκείνοι οι εξερχόμενοι κόμβοι που διαθέτουν την ιδιότητα του άντρα, του αδελφού και του παιδιού και συνδέονται με την Γεωργία, τέλος αποθηκεύονται τα ονόματα των κόμβων σαν στόχος έτσι ώστε να υπάρχει η οπτικοποιήση τους.

Το επόμενο και τελευταίο ερώτημα οπτικοποιήσης εμφανίζει τόσα τα εγγόνια της Γεωργίας όσο και τους ενδιάμεσους κόμβους αυτών, δηλαδή τα παιδία της, η σύνταξη του έχει ως έξης: **graph.V("georgia").Save('name', 'source').As('source').Out('child', 'relation').Save('name', 'target').As('target').ForEach(function(d) {**

g.Emit(d);

g.V(d.id).Save('name', 'source').As('source').Out('child', 'relation').Save('name', 'target').As('target').ForEach(function(d2) {

g.Emit(d2);

});

});

και αποτέλεσμα του ερωτήματος εμφανίζεται στην Εικόνα 20.

Η σύνταξη του παραπάνω ερωτήματος είναι πιο σύνθετη, αρχικά ορίζει τον κόμβο της Γεωργίας, τον αποθηκεύει με το όνομα του σαν πηγή προκειμένου να υπάρξει απεικόνιση και στην συνεχεία ζητάει να εμφανιστούν με το στοιχείο out,όσοι εξερχόμενοι κόμβοι έχουν την ιδιότητα “παιδί” και αποθηκεύει το όνομα αυτών των κόμβων προκειμένου να υπάρξει απεικόνιση των ενδιάμεσων κόμβων, δηλαδή των παιδιών της Γεωργίας.

Στην συνεχεία για να εμφανιστούν και οι τελικοί κόμβοι δηλαδή τα εγγόνια της Γεωργίας, επαναλαμβάνεται το ερώτημα ακριβώς με την ίδια σύνταξη.

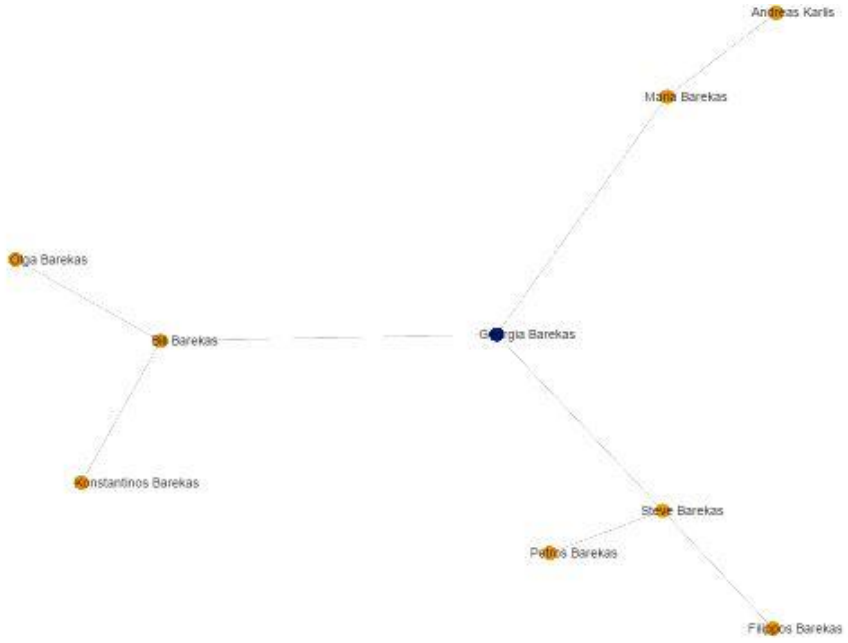

Εικόνα 20 – Οι κόμβοι των παιδιών και των εγγονιών της Γεωργίας

6. Βιβλιογραφία

Βιβλία

- Ian Robinson, Jim Webber, and Emil Eifrem, Graph Databases, Chapter 1,2 &5, O'Reilly Media

Άρθρα

- Dan Ariely, An Architecture for Massively Scalable, Intelligent Applications, Duke University, May 2016
- Benjamin Erb,Concurrent Programming for Scalable Web ArcitectureGraph Databases
- Mihail, Google Cayley graph database tutorial - family tree, June 2016
- Vicknair, C., Macias, M., Zhao, Z., Nan, X., Chen, Y., & Wilkins, D. (2010). A Comparison of a Graph Database and a Relational. ACM SE '10 Proceedings of the 48th Annual SoutheastRegional Conference (ς. 42). New York: ACM New York, NY, USA ©2010

Ιστότοποι

- https://el.wikipedia.org/wiki/ACID
- http://www.linuxinsider.gr/forum/8873/eisagogi-stis-nosql-baseis-dedomenon-xrisi-toy-cassandra
- https://en.wikipedia.org/wiki/Column-oriented_DBMS
- https://db-engines.com/en/article/Key-value+Stores
- https://en.wikipedia.org/wiki/Document-oriented_database
- https://neo4j.com/developer/graph-database/
- https://neo4j.com/developer/graph-db-vs-rdbms/
- https://neo4j.com/developer/graph-db-vs-rdbms/
- https://en.wikipedia.org/wiki/Neo4j
- https://franz.com/agraph/support/documentation/current/agraph-introduction.html
- https://www.oracle.com/database/spatial/index.html
- http://www.objectivity.com/products/infinitegraph/
- https://opensource.googleblog.com/2014/06/cayley-graphs-in-go.html

- http://www.i-programmer.info/news/84-database/7492-google-cayley-graph-database.html
- https://aws.amazon.com/blogs/big-data/building-a-graph-database-on-aws-using-amazon-dynamodb-and-titan/
- http://gremlindocs.spmallette.documentup.com/
- https://github.com/tinkerpop/gremlin/wiki/Defining-a-Property-Graph
- https://github.com/tinkerpop/gremlin/wiki/The-Benefits-of-Gremlin

Παρουσιάσεις

- Michael Povolotsky, Virtuoso
- Jarek Wilkiewicz, Shawn Simister, When 2 billion Freebase facts is not enough, SemTechBiz ‘14 LODLAM Workshop