

УДК 004.423

ГИБРИДНЫЙ ПОДХОД К РЕЗЕРВНОМУ КОПИРОВАНИЮ РАЗНОРОДНЫХ ИСТОЧНИКОВ ДАННЫХ: POSTGRESQL И ФАЙЛОВЫЕ СИСТЕМЫ

Халевин Т.А.

*студент направления подготовки информатика и вычислительная техника,
Хакасский государственный университет имени Н.Ф. Катанова,
г. Абакан, Россия ¹*

Аннотация: Современные организации используют разнородные системы хранения данных, а существующие коммерческие решения для резервного копирования часто негибкие и дорогие. Целью работы стала разработка гибридной системы для PostgreSQL и файловых систем, обеспечивающей высокий уровень безопасности и автоматизации. Представлена модульная архитектура с потоковым копированием баз данных, шифрованием AES-256-GCM, алгоритмом обнаружения аномалий и персистентными уведомлениями через Telegram. Экспериментальное тестирование показало двукратное снижение использования дискового пространства, 99.7% успешность создания архивов и 100% сохранность уведомлений при перезапусках. Решение демонстрирует эффективность унифицированного подхода к защите гетерогенных данных и может служить основой для промышленных систем.

Ключевые слова: резервное копирование, PostgreSQL, файловые системы, конвертное шифрование, аномалии данных, автоматизация, Golang

A HYBRID APPROACH TO BACKING UP HETEROGENEOUS DATA SOURCES: POSTGRESQL AND FILE SYSTEMS

Khalevin T.A.

student of computer science and computer engineering department,

¹ Научный руководитель: Козлитин Р.А. канд. физ.-мат. наук, доцент кафедры ПОВТиАС, Хакасский государственный университет имени Н.Ф. Катанова, г. Абакан, Россия

*N.F. Katanov Khakass State University,
Abakan, Russia*

Abstract: Modern organizations use diverse data storage systems, and existing commercial backup solutions are often inflexible and expensive. The goal of this work was to develop a hybrid system for PostgreSQL and file systems that provides a high level of security and automation. A modular architecture with streaming database copying, AES-256-GCM encryption, an anomaly detection algorithm, and persistent notifications via Telegram is presented. Experimental testing showed a twofold reduction in disk space usage, 99.7% success rate in creating archives, and 100% preservation of notifications during restarts. The solution demonstrates the effectiveness of a unified approach to protecting heterogeneous data and can serve as a basis for industrial systems.

Keywords: backup, PostgreSQL, file systems, envelope encryption, data anomalies, automation, Golang

Современные предприятия сталкиваются с необходимостью защиты разнородных данных: от структурированной информации в реляционных базах данных до неструктурированных файлов операционных систем. Традиционные подходы к резервному копированию часто требуют использования специализированных решений для каждого типа источника данных, что усложняет администрирование и увеличивает стоимость владения системой.

Проблема усугубляется требованиями к безопасности данных, необходимостью обеспечения целостности архивов и потребностью в оперативном мониторинге состояния процессов резервного копирования.

Актуальность состоит в том, что существующие коммерческие решения часто не обеспечивают достаточной гибкости для специфических требований организаций или имеют высокую стоимость лицензирования.

Цель данной работы — разработка и анализ структуры гибридной системы резервного копирования, способной эффективно работать с различными типами источников данных при обеспечении высокого уровня безопасности и автоматизации процессов.

Анализ современного рынка решений для резервного копирования показывает преобладание двух основных подходов:

Специализированные решения фокусируются на определенном типе данных. Например, `pg_dump` и `pg_basebackup` для PostgreSQL обеспечивают создание логических и физических копий баз данных соответственно, но не работают с файловыми системами. Утилиты `rsync`, `tar`, и коммерческие файловые агенты эффективно копируют файлы, но не понимают специфику СУБД.

Универсальные платформы (Veeam, Commvault, Veritas NetBackup) предлагают поддержку множества источников данных, но требуют значительных инвестиций в лицензии и обучение персонала. Кроме того, они часто избыточны для организаций с ограниченными требованиями [1].

Недостатки существующих подходов:

- Фрагментированность решений увеличивает операционную сложность
- Отсутствие единой системы мониторинга и уведомлений
- Ограниченные возможности кастомизации процессов
- Высокая стоимость владения коммерческими решениями
- Недостаточная автоматизация обнаружения аномалий

Предлагаемая структура основана на модульном подходе с четким разделением ответственности между компонентами. Схема представлена на рисунке 1.



Рисунок 1 – Структура решения

На рисунке 2, модуль обработки источников данных реализует стратегию для каждого типа источника.

```
type Source struct {  
    ID string `yaml:"id"`  
    Type string `yaml:"type" // "postgres" | "files"  
    BackupName string `yaml:"backup_name"`  
    DSN string `yaml:"dsn" // для PostgreSQL  
    Path string `yaml:"path" // для файлов  
    PGDumpOpts []string `yaml:"pg_dump_opts"`  
    AdditionalBackupDir string `yaml:"additional_backup_dir"`  
}
```

Рисунок 2 – Структура с каждым типом источника данных

Для PostgreSQL используется потоковое копирование с прямым сжатием. В этом процессе команда `pg_dump` выполняется с передачей `stdout` в `gzip writer`, что позволяет избежать создания промежуточных файлов и экономит дисковое пространство. Кроме того, через конфигурацию поддерживаются все опции `pg_dump`, обеспечивая гибкость настройки.

Для файловых систем реализован двухэтапный процесс: сначала исходный файл копируется во временную директорию, а затем архивируется с использованием `gzip` (для Linux) или `zip` (для Windows).

На рисунке 3, модуль криптографической защиты реализует `envelope encryption` по стандарту AES-256-GCM.

```
type Container struct {  
    Version    int    `json:"version"`  
    Alg        string `json:"alg"`           // "AES-256-GCM"  
    WrapAlg    string `json:"wrap_alg"`     // "AES-256-GCM"  
    KEKID      string `json:"kek_id"`       // идентификатор KEK  
    WrappedDEK string `json:"wrapped_dek"`  // зашифрованный DEK  
    Ciphertext string `json:"ciphertext"`   // данные конфигурации  
}
```

Рисунок 3 – Модуль AES-256-GCM

Структура предусматривает автоматическую генерацию Key Encryption Key (KEK) – криптографического ключа, использование уникального Data Encryption Key (DEK) – симметричного криптографического ключа, для каждого сеанса, атомарные операции записи зашифрованных конфигураций, а также проверку целостности через AEAD-теги.

Реализован алгоритм обнаружения аномалий размера архивов на основе скользящей медианы и изображен на рисунке 4.

```
func detectSizeAnomaly(current int64, median float64, thresholdPercent float64) (bool, float64) {  
    if median == 0 {  
        return false, 0  
    }  
    delta := (median - float64(current)) / median * 100.0  
    return delta >= thresholdPercent, delta  
}
```

Рисунок 4 – Алгоритм обнаружения аномалий размера архивов

Алгоритм анализирует последние N архивов (по умолчанию 5), вычисляет медианное значение размера и определяет отклонение текущего архива. При превышении порогового значения (по умолчанию 20%) система генерирует предупреждение.

Telegram-интеграция обеспечивает персистентную очередь сообщений с использованием BoltDB, ограничение скорости для соблюдения ограничений API, retry-логику с экспоненциальным откладыванием и шаблонизацию сообщений с контекстными данными.

Структура данной интеграции изображена на рисунке 5.

```
type TelegramNotifier struct {  
    cfg      TelegramConfig  
    client   *http.Client  
    queue    persistentQueue  
    limiter  *tokenBucket  
    templates map[string]string  
}
```

Рисунок 5 – Типовая структура для телеграмм-интеграции

Система адаптируется к особенностям операционных систем. В среде Linux это выражается в использовании tar.gz для архивации, строгой проверке прав доступа к криптографическим ключам (0600) и поддержке системных путей, таких как /var/lib/backup_app/. Для Windows, в свою очередь, реализовано использование ZIP-архивов, адаптированные пути вида C:\ProgramData\BackupApp\ и упрощенная проверка безопасности файлов [2].

Управление жизненным циклом архивов также автоматизировано. Автоматическая ротация реализована через конфигурируемое количество сохраняемых копий, сортировку по времени модификации, атомарное удаление устаревших файлов и специальную обработку пятничных копий для долгосрочного хранения. Вся реализация этого процесса изображена на рисунке 6.

```
func enforceRetention(backupDir, backupName string, retentionCount int) ([]string, error) {  
    pattern := filepath.Join(backupDir, fmt.Sprintf("%s-*.dump.*", backupName))  
    matches, err := filepath.Glob(pattern)  
    // Сортировка по времени, удаление лишних  
}
```

Рисунок 6 – Функция автоматической ротации архивов

Система обеспечивает высокую производительность за счет поддержки настраиваемого количества параллельных процессов резервного копирования, использования объединения рабочих потоков для обработки уведомлений, выполнения неблокирующих операций с очередью сообщений и реализации мягкое выключение с ожиданием завершения активных операций [3].

Тестирование проводилось в среде, включающей операционные системы Ubuntu 20.04 LTS и Windows Server 2019. В качестве СУБД использовались

PostgreSQL версий с 12 по 15. Размеры тестовых баз данных варьировались от 100 МБ до 50 ГБ, а размеры файлов – от 1 ГБ до 10 ГБ.

В таблице 1 представлены результаты тестирования систем резервного копирования и их сравнение.

Таблица 1 – Результаты экспериментального тестирования гибридной системы резервного копирования

Метрика	PostgreSQL (поточковый режим)	Файлы	Традиционный подход	Улучшение
Производительность				
Время создания архива (10 ГБ)	8.2 мин	12.5 мин	11.3 мин	↑ 27%
Использование дискового пространства	10.1 ГБ	10.8 ГБ	20.2 ГБ	↓ 50%
Пиковая нагрузка на I/O (МБ/с)	145	180	285	↓ 49%
Надежность				
Успешность создания архивов	99.7%	99.5%	98.1%	↑ 1.6 п.п.
Обнаружение поврежденных данных	96.3%	94.8%	н/д	—
Ложноположительные аномалии (порог 20%)	1.8%	2.1%	н/д	—
Уведомления				
Доставка при стабильной сети	100%	100%	95.2%	↑ 4.8 п.п.
Доставка при нестабильной сети	99.8%	99.8%	76.5%	↑ 23.3 п.п.
Среднее время доставки (сек)	3.2	3.5	12.8	↓ 75%
Сохранность после перезапуска	100%	100%	0%	↑ 100 п.п.
Безопасность				
Время шифрования конфигурации (мс)	42	45	н/д	—
Накладные расходы на шифрование	2.1%	2.3%	н/д	—
Успешность дешифрования	100%	100%	н/д	—

Экспериментальные данные демонстрируют значительное преимущество потокового подхода для PostgreSQL: экономия дискового пространства в 2 раза и снижение нагрузки на подсистему ввода-вывода почти вдвое. Система обнаружения аномалий показала высокую точность при минимальном уровне

ложных срабатываний, что критически важно для своевременного выявления проблем целостности данных.

Ключевое преимущество структуры проявляется в подсистеме уведомлений: персистентная очередь на основе BoltDB обеспечивает 100% сохранность сообщений при перезапусках системы (против 0% у решений без персистентности) и троекратное улучшение надежности доставки в условиях нестабильной сети. Это делает систему особенно пригодной для критических инфраструктур, где потеря уведомлений о сбоях недопустима.

Система проектировалась для минимального воздействия на существующие процессы. Для этого используются стандартные инструменты, такие как `pg_dump`, а настройка осуществляется через удобные YAML-конфигурации. Предусмотрена интеграция с уже работающими системами мониторинга через Telegram, а также поддержка pre/post hooks для реализации любой кастомной логики.

Разработанная структура демонстрирует эффективность гибридного подхода к резервному копированию разнородных источников данных. Ключевые преимущества этого решения включают унификацию процессов, автоматизацию мониторинга, криптографическую защиту и высокую операционную эффективность.

Дальнейшее развитие системы предполагает расширение ее функциональности. В планах – поддержка дополнительных СУБД, таких как MySQL и Oracle, интеграция с облачными хранилищами, включая S3 и Azure Blob, а также реализация инкрементального резервного копирования. Для удобства управления будет создан web-интерфейс для мониторинга, а также добавлена поддержка кластерных конфигураций PostgreSQL.

При этом текущая реализация имеет ряд ограничений. Среди них – отсутствие поддержки восстановления на момент времени для PostgreSQL и ограниченная масштабируемость при работе с очень большими объемами

данных. Кроме того, система зависит от доступности Telegram API для отправки критически важных уведомлений.

Представленное решение может служить основой для создания промышленных систем резервного копирования, адаптированных под специфические требования организаций с гетерогенной IT-инфраструктурой.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Smith J., Johnson K. Database Backup Strategies for Enterprise Environments / Smith J., Johnson K. // ACM Transactions on Database Systems. – 2022. – Vol. 47, No. 2. P. 1-24.
2. Williams R. Cryptographic Protection of Backup Data: Best Practices and Implementation / Williams R. – IEEE Security & Privacy. – 2023. – Vol. 21, No. 1. P. 34-41.
3. PostgreSQL Global Development Group. PostgreSQL Documentation: Backup and Restore / PostgreSQL Global Development Group. - PostgreSQL Manual. – 2023. – Version 15.

Оригинальность 77%