O'REILLY®

Wydanie II

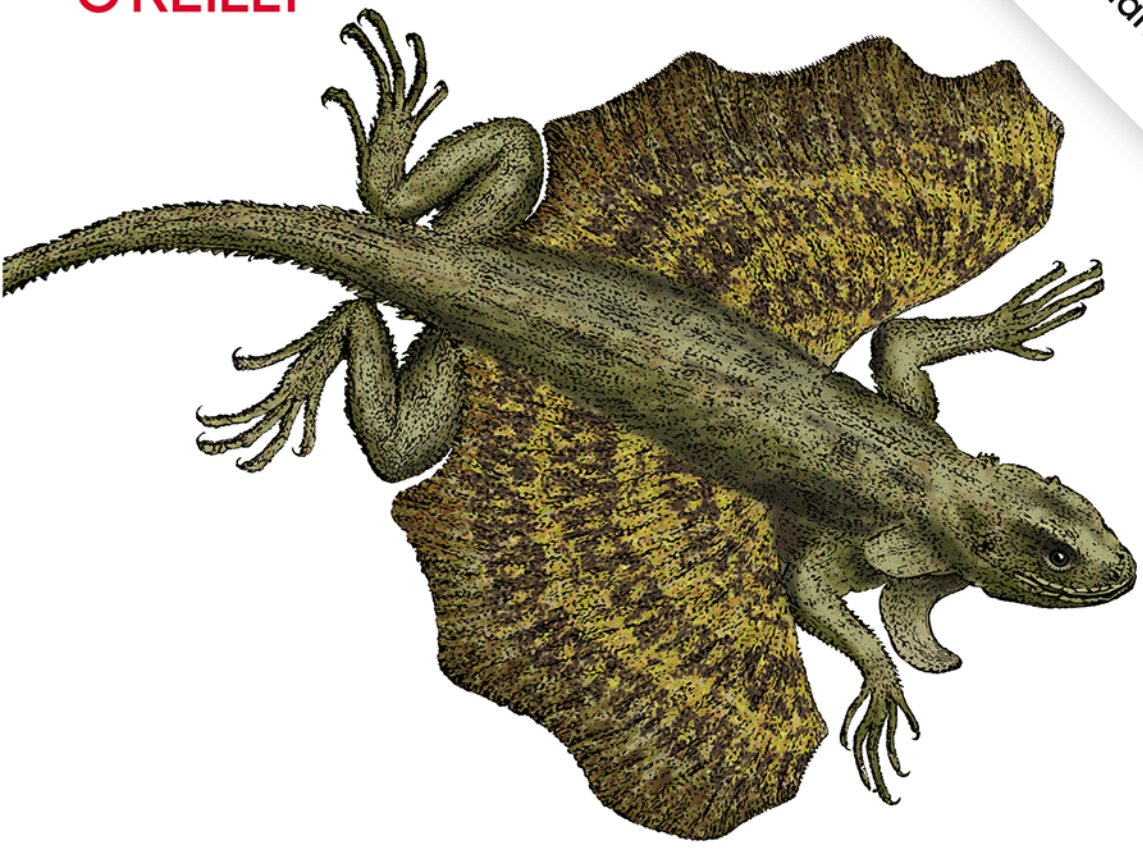

Terraform

Krótkie wprowadzenie

Tworzenie infrastruktury za pomocą kodu

Helion

Yevgeniy Brikman

Tytuł oryginału: Terraform: Up & Running: Writing Infrastructure as Code, 2nd Edition

Tłumaczenie: Robert Górczyński

ISBN: 978-83-283-6649-7

Helion SA
ul. Kościuszki 1c, 44-100 Gliwice
tel. 32 231 22 19, 32 230 98 63
e-mail: *helion@helion.pl*
WWW: *http://helion.pl* (księgarnia internetowa, katalog książek)

Pliki z przykładami omawianymi w książce można znaleźć pod adresem:
ftp://ftp.helion.pl/przyklady/terra2.zip

Drogi Czytelniku!
Jeżeli chcesz ocenić tę książkę, zajrzyj pod adres
http://helion.pl/user/opinie/terra2
Możesz tam wpisać swoje uwagi, spostrzeżenia, recenzję.

Printed in Poland.

Spis treści

ROZDZIAŁ 1.

Dlaczego Terraform?

Oprogramowanie nie jest uznawane za gotowe, gdy kod działa w komputerze programisty. Nie jest również gotowe po zaliczeniu wszystkich testów lub gdy ktoś stwierdzi: „Można wydać tę aplikację". Oprogramowanie nie może być uznane za gotowe aż do chwili jego *dostarczenia* użytkownikowi.

Dostarczanie oprogramowania oznacza wykonanie pracy niezbędnej w celu udostępnienia kodu klientowi, np. uruchomienie tego kodu w serwerach produkcyjnych, utworzenie kodu w sposób odporny na przestój lub maksymalne obciążenie sieci, a także zapewnienie ochrony kodu przed atakami. Zanim zagłębisz się w szczegóły związane z Terraform, warto wykonać krok wstecz i spojrzeć z szerszej perspektywy na to, jak Terraform wpasowuje się w proces dostarczania oprogramowania.

W rozdziale zostaną poruszone zagadnienia:

- powstanie ruchu DevOps,
- infrastruktura jako kod,
- korzyści z infrastruktury jako kodu,
- sposób działania Terraform,
- porównanie Terraform z innymi narzędziami infrastruktury jako kodu.

Powstanie ruchu DevOps

W nie tak odległej przeszłości, jeśli chciało się zbudować firmę zajmującą się tworzeniem oprogramowania, trzeba było zajmować się również zarządzaniem mnóstwem sprzętu komputerowego. Konieczne było przygotowanie szafek i umieszczenie w nich serwerów w obudowach typu rack, wykonanie niezbędnych połączeń między poszczególnymi urządzeniami, przygotowanie chłodzenia, utworzenie awaryjnego systemu zasilania itd. Sensowne wydawało się posiadanie jednego zespołu, zwykle nazywanego programistami (ang. *developers*), odpowiedzialnego za tworzenie oprogramowania, i drugiego zespołu, zwykle określanego operacyjnym (ang. *operations*), odpowiedzialnego za zarządzanie dostępnym sprzętem komputerowym.

Zespół programistów tworzył aplikację, a następnie przekazywał ją zespołowi operacyjnemu, którego zadaniem było ustalenie, jak ją wdrożyć i uruchomić. Większość zadań była wykonywana ręcznie. Po części było to nieuniknione, ponieważ większość pracy wiązała się fizycznie z urządzeniami (np. układanie serwerów, łączenie urządzeń kablami itd.). Jednak nawet związane z oprogramowa-

niem zadania w zespole operacyjnym, takie jak instalowanie aplikacji i jej zależności, bardzo często były wykonywane ręcznie przez wydawanie poleceń w serwerze.

Wprawdzie na początku takie rozwiązanie się sprawdza, ale wraz z rozwojem i ze wzrostem firmy pojawiają się problemy. Najczęściej spotykamy się z następującą sytuacją: ponieważ wydania są realizowane ręcznie, wraz ze wzrostem liczby serwerów wydania stają się wolne, bolesne i nieprzewidywalne. Zespół operacyjny czasami popełnia błędy, czego efektem są *minimalne różnice* w konfiguracji poszczególnych serwerów (ten problem jest często określany mianem *zmiany konfiguracji*). To z kolei przekłada się na wzrost liczby błędów. Programiści bronią się twierdzeniem „to działa w moim komputerze", a przestoje pojawiają się znacznie częściej.

Pracownicy działu operacyjnego, zmęczeni telefonami o trzeciej w nocy po każdym nowym wydaniu oprogramowania, zmniejszają częstotliwość tych wydań do jednego tygodniowo. Następnie do jednego miesięcznie, a później do jednego co pół roku. Na tygodnie przed wydaniem oprogramowania w danym półroczu zespoły próbują ujednolicić projekty, co prowadzi do ogromnego bałaganu i rodzi konflikty. Nikt nie potrafi ustabilizować gałęzi zawierającej wersję oprogramowania przeznaczoną do wydania. Zespoły zaczynają nawzajem zrzucać na siebie odpowiedzialność. Sytuacja staje się trudna i wydaje się, że firma wkrótce stanie.

Obecnie jesteśmy świadkami ogromnej zmiany w tym zakresie. Zamiast zarządzać własnymi centrami danych, wiele firm korzysta z chmury i czerpie korzyści z dostępności usług takich jak Amazon Web Services (AWS), Microsoft Azure i Google Cloud Platform (GCP). Zamiast inwestycji ogromnych środków w sprzęt wiele zespołów operacyjnych zajmuje się pracą nad oprogramowaniem, wykorzystując do tego narzędzia takie jak Chef, Puppet, Terraform i Docker. Zamiast zmagać się z ustawianiem serwerów i łączeniem przewodów sieciowych, wielu administratorów systemów zajmuje się tworzeniem kodu.

W efekcie zespoły programistyczny i operacyjny poświęcają większość czasu na pracę nad oprogramowaniem, a granica między nimi powoli się zaciera. Nadal rozsądne jest posiadanie oddzielnego zespołu programistów odpowiedzialnych za obsługę kodu aplikacji i zespołu operacyjnego odpowiedzialnego za obsługę kodu operacyjnego, choć nie ulega wątpliwości, że obie te grupy muszą ściślej ze sobą współpracować. W taki sposób dotarliśmy do *ruchu DevOps*.

DevOps nie jest nazwą zespołu, stanowiska lub konkretnej technologii. To raczej zbiór procesów, idei i technik. Każdy ma nieco inną definicję DevOps, ale na potrzeby materiału przedstawionego w książce będę wykorzystywał następującą:

> *Celem DevOps jest znacznie efektywniejsze dostarczanie oprogramowania.*

Zamiast wielodniowych, koszmarnych operacji łączenia projektów kod jest integrowany nieustannie i zawsze pozostaje w stanie pozwalającym na jego wdrożenie. Zamiast raz w miesiącu wdrożenia kodu mogą być przeprowadzane wielokrotnie w ciągu dnia, a nawet wraz z każdą operacją przekazania kodu do repozytorium. Ponadto zamiast stałych przestojów tworzy się odporny i samonaprawiający się system, a rozwiązania z zakresu monitorowania i ostrzegania wykorzystuje do wychwytywania problemów, które nie mogą być usunięte automatycznie.

Wyniki firm, które zdecydowały się na zastosowanie podejścia DevOps, są zdumiewające. Przykładowo firma Nordstorm przekonała się, że zastosowanie praktyk DevOps w organizacji pozwoliło na zwiększenie o 100% liczby funkcji dostarczanych każdego miesiąca, skrócenie liczby usterek o połowę, skrócenie o 60% *czasu realizacji* (ang. *lead time*) — w tym kontekście to opóźnienie między pojawieniem się pomysłu i uruchomienie kodu w środowisku produkcyjnym — oraz zmniejszenie liczby incydentów produkcyjnych o 60 – 90%. Gdy dział LaserJet Firmware w HP zaczął stosować praktyki DevOps, czas poświęcany przez programistów na tworzenie kodu wzrósł z 5% do 40%, a ogólny koszt prac programistycznych spadł o 40%. Z kolei firma Etsy wykorzystała praktyki DevOps w celu przejścia od stresujących i rzadkich wdrożeń powodujących przestoje i awarie do wielokrotnych wdrożeń w ciągu dnia (od 25 do 50) wraz ze znacznie niższą liczbą przestojów[1].

Mamy cztery podstawowe wartości w ruchu DevOps — są to: kultura, automatyzacja, pomiar i współdzielenia, co czasami jest określane akronimem CAMS (ang. *culture*, *automation*, *measurement*, *sharing*). Ta książka nie jest wyczerpującym przewodnikiem po ruchu DevOps (materiały na ten temat, z którymi warto się zapoznać, wymieniłem w dodatku A), więc zamierzam skoncentrować się tylko na jednej z wymienionych wartości: automatyzacji.

Celem jest jak największa automatyzacja procesu dostarczania oprogramowania. To oznacza zarządzanie infrastrukturą nie przez klikanie na stronie internetowej lub ręczne wydawanie poleceń w powłoce, ale za pomocą kodu. Ta koncepcja jest zwykle określana mianem *infrastruktura jako kod*.

Infrastruktura jako kod

Idea stojąca za infrastrukturą jako kodem (ang. *infrastructure as code*, IaC) polega na tworzeniu i wykonywaniu kodu w celu zdefiniowania, uaktualnienia i usunięcia infrastruktury. To pokazuje ważną zmianę w nastawieniu, polegającą na tym, że wszystkie aspekty operacji są traktowane jako oprogramowanie — nawet te związane z przestawieniem sprzętu (np. fizyczne umieszczenie serwera w pewnym miejscu). Przy czym kluczowe znaczenie w praktykach DevOps ma to, że niemalże *wszystkim* można zarządzać w kodzie: serwerami, bazami danych, sieciami, plikami dzienników zdarzeń, konfiguracją aplikacji, dokumentacją, testami zautomatyzowanymi, procesami wdrażania itd.

Istnieje pięć szerokich kategorii narzędzi IaC:

- skrypty tymczasowe,
- narzędzia zarządzania konfiguracją,
- narzędzia szablonów serwera,
- narzędzia instrumentacji,
- narzędzia provisioningu.

Dalej po kolei przedstawię te kategorie.

[1] Te informacje pochodzą z książki *DevOps. Światowej klasy zwinność, niezawodność i bezpieczeństwo w Twojej organizacji* (Helion), której autorami są Gene Kim, Patrick Debois, John Willis, Jez Humble i John Allspaw.

Skrypty tymczasowe

Najprostsze podejście w zakresie automatyzacji czegokolwiek polega na utworzeniu *skryptu tymczasowego*. Zadanie przeznaczone do ręcznego wykonania dzielisz na kolejne kroki, a następnie używasz ulubionego języka skryptowego (np. Bash, Ruby, Python) do zdefiniowania poszczególnych kroków w kodzie i wykonujesz skrypt w serwerze, jak pokazałem na rysunku 1.1.

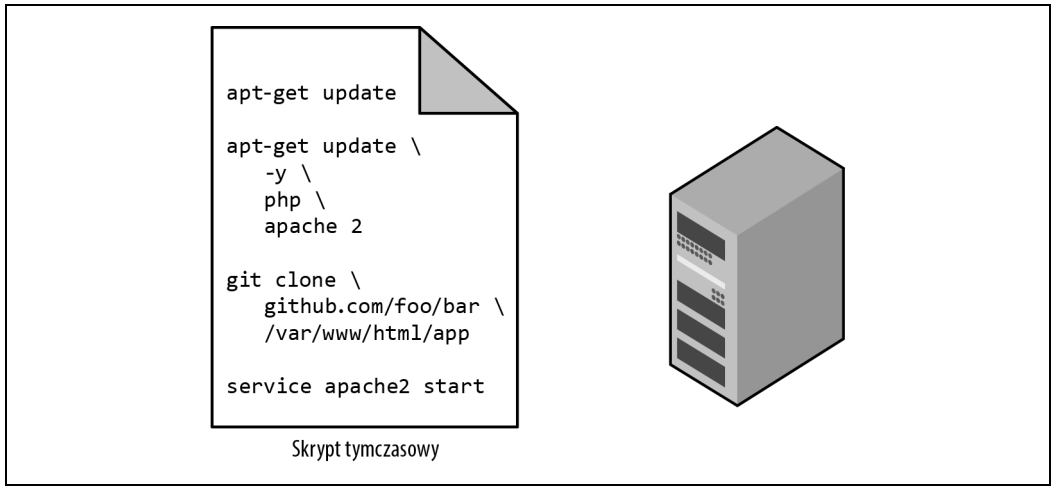

Rysunek 1.1. Uruchamianie skryptu tymczasowego w serwerze

Dla przykładu spójrz na przedstawiony tutaj skrypt Bash o nazwie *setup-webserver.sh* przeprowadzający konfigurację serwera przez zainstalowanie zależności, pobranie kodu z repozytorium Git i uruchomienie serwera WWW Apache:

```
# Uaktualnienie bufora narzędzia apt-get.
sudo apt-get update

# Instalacja PHP i Apache.
sudo apt-get install -y php apache2

# Pobranie kodu z repozytorium.
sudo git clone https://github.com/brikis98/php-app.git /var/www/html/app

# Uruchomienie serwera Apache.
sudo service apache2 start
```

Ogromną zaletą i jednocześnie największą wadą skryptów tymczasowych jest możliwość użycia popularnych języków programowania ogólnego przeznaczenia i utworzenie kodu w dowolny sposób.

Podczas gdy narzędzia opracowane specjalnie z myślą o IaC dostarczają spójne API przeznaczone do wykonywania skomplikowanych zadań, to jeśli używasz języka programowania ogólnego przeznaczenia, musisz tworzyć niestandardowy kod dla każdego zadania. Co więcej, narzędzia zaprojektowane dla IaC zwykle wymuszają stosowanie określonej struktury kodu, w przypadku języków programowania ogólnego przeznaczenia zaś każdy programista ma własny styl i inaczej wykonuje pewne zadania. Żadna z wymienionych kwestii nie stanowi poważnego problemu w ośmiowierszowym skrypcie instalującym serwer Apache, ale sytuacja szybko wymknie się spod kontroli, gdy skrypty tymczasowe

będą używane do zarządzania dziesiątkami serwerów, baz danych, mechanizmów równoważenia obciążenia, konfiguracji sieciowych itd.

Jeżeli kiedykolwiek musiałeś obsługiwać ogromne repozytorium skryptów Bash, doskonale wiesz, że praktycznie zawsze prowadzi to do powstania niemożliwego w zarządzaniu tzw. *kodu spaghetti*. Skrypty tymczasowe doskonale sprawdzają się podczas wykonywania jednorazowych zadań. Jeżeli zamierzasz zarządzać całą infrastrukturą jako kodem, powinieneś zdecydować się na dedykowane IaC narzędzie opracowane do wykonywania konkretnych zadań.

Narzędzia zarządzania konfiguracją

Chef, Puppet, Ansible i SaltStack to przykłady *narzędzi zarządzania konfiguracją*, co oznacza, że zostały zaprojektowane do instalowania oprogramowania w istniejących serwerach oraz zarządzania nim. Dla przykładu w kolejnym fragmencie kodu przedstawiłem *rolę Ansible* o nazwie *web-server.yml* odpowiedzialną za taką samą konfigurację serwera WWW Apache, jaka wcześniej była przeprowadzana w skrypcie *setup-webserver.sh*.

```
- name: Uaktualnienie bufora narzędzia apt-get.
  apt:
    update_cache: yes

- name: Instalacja PHP.
  apt:
    name: php

- name: Instalacja Apache.
  apt:
    name: apache2

- name: Pobranie kodu z repozytorium.
  git: repo=https://github.com/brikis98/php-app.git dest=/var/www/html/app

- name: Uruchomienie serwera Apache.
  service: name=apache2 state=started enabled=yes
```

Ten kod jest podobny do użytego w skrypcie Bash, ale wykorzystanie narzędzia takiego jak Ansible ma wiele zalet, z których tutaj wymieniłem tylko kilka:

Konwencje tworzenia kodu

Ansible wymusza spójność, przewidywalną strukturę, dołączanie dokumentacji, stosowanie pewnego układu plików, czytelne nazwy parametrów, zarządzanie informacjami niejawnymi itd. Podczas gdy każdy programista tworzy skrypty tymczasowe w odmienny sposób, większość narzędzi zarządzania konfiguracją jest dostarczana wraz z zestawem konwencji ułatwiających poruszanie się po kodzie.

Powtarzalność

Utworzenie jednorazowo wykonywanego skryptu tymczasowego nie należy do zbyt trudnych zadań. Z kolei opracowanie skryptu tymczasowego, który będzie działał prawidłowo nawet wtedy, gdy jest w ciągłym użyciu, to znacznie trudniejsze zadanie. Za każdym razem, gdy będziesz tworzyć katalog za pomocą kodu w skrypcie, musisz pamiętać o sprawdzeniu, czy ten katalog

istnieje. Za każdym razem, gdy dodasz wiersz konfiguracyjny do pliku, musisz sprawdzić, czy taki wiersz jeszcze nie istnieje. Jeżeli chcesz uruchomić aplikację, musisz sprawdzić, czy nie została uruchomiona już wcześniej.

Kod działający poprawnie niezależnie od liczby jego uruchomień jest nazywany *kodem powtarzalnym*. Aby zagwarantować powtarzalność przedstawionego wcześniej skryptu Bash, musiałbyś dodać wiele wierszy kodu zawierających dużo konstrukcji `if`. Z kolei większość funkcji Ansible domyślnie zapewnia powtarzalność. Przykładowo kod w pliku *web-server.yml* zainstaluje oprogramowanie Apache tylko, jeśli nie jest ono zainstalowane, spróbuje uruchomić serwer WWW Apache tylko, jeśli nie został uruchomiony wcześniej.

Dystrybucja

Skrypty tymczasowe są przeznaczone do działania w pojedynczym komputerze lokalnym. Ansible i inne narzędzia służące do zarządzania konfiguracją zostały zaprojektowane specjalnie do zarządzania ogromną liczbą zdalnych serwerów, jak możesz zobaczyć na rysunku 1.2.

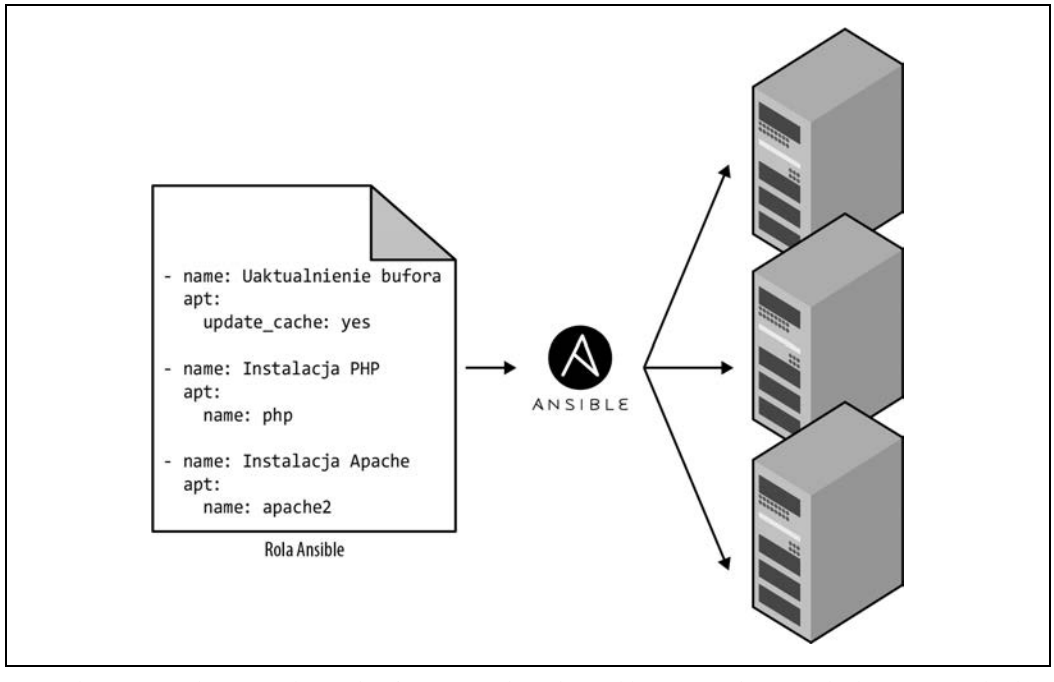

Rysunek 1.2. Narzędzie zarządzania konfiguracją, takie jak Ansible, może wykonywać kod w ogromnej liczbie serwerów

Przykładowo, aby zastosować rolę *web-server.yml* w pięciu serwerach, trzeba zacząć od utworzenia pliku o nazwie *hosts* zawierającego adresy IP tych serwerów.

```
[webservers]
11.11.11.11
11.11.11.12
11.11.11.13
11.11.11.14
11.11.11.15
```

Teraz można zdefiniować następujący tzw. *playbook Ansible*:

```
- hosts: webservers
  roles:
  - webserver
```

Na końcu można za pomocą przedstawionego polecenia wykonać zdefiniowany kod:

```
ansible-playbook playbook.yml
```

To nakazuje Ansible równoczesne skonfigurowanie wszystkich pięciu serwerów. Ewentualnie za pomocą polecenia o nazwie `serial` umieszczonego we wspomnianym playbooku Ansible można zdefiniować wdrożenie określane mianem *rolling deployment*, które będzie seriami uaktualniało serwery. Dlatego też przypisanie parametrowi `serial` wartości `2` oznacza, że Ansible będzie jednocześnie uaktualniać dwa serwery, a sama operacja zostanie wielokrotnie powtórzona, aż do chwili skonfigurowania wszystkich serwerów (w omawianym przykładzie jest to pięć serwerów). Powielenie tej logiki w skrypcie tymczasowym może zabrać dziesiątki lub nawet setki wierszy kodu.

Narzędzia szablonów serwera

Zyskującym ostatnio popularność rozwiązaniem alternatywnym dla zarządzania konfiguracją jest wykorzystanie *narzędzi szablonów serwera*, takich jak Docker, Packer i Vagrant. Zamiast na uruchamianiu ogromnej liczby serwerów i konfigurowaniu ich przez wykonywanie tego samego kodu w każdym z nich idea stojąca za narzędziami szablonów serwera polega na utworzeniu *obrazu* serwera zawierającego pełną „migawkę" systemu operacyjnego (OS), oprogramowania, plików i wszelkich innych ważnych elementów. Następnie za pomocą narzędzia typu IaC można ten obraz zainstalować we wszystkich serwerach, jak pokazałem na rysunku 1.3.

Jak widać na rysunku 1.4, istnieją dwie szerokie kategorie narzędzi przeznaczonych do pracy z obrazami.

Maszyny wirtualne

Maszyna wirtualna (ang. *virtual machine*, VM) emuluje cały system komputerowy, wraz ze sprzętem. Uruchamiasz program tzw. *hipernadzorcy* (ang. *hypervisor*) — taki jak VMware, VirtualBox, Parallels itd. — w celu wirtualizacji (czyli symulowania) procesora, pamięci, dysku twardego i sieci. Zaletą takiego rozwiązania jest to, że każdy *obraz maszyny wirtualnej* uruchamiany przez hipernadzorcę może mieć dostęp jedynie do wirtualizowanego sprzętu, więc tym samym pozostaje w pełni odizolowany od komputera gospodarza i pozostałych obrazów VM. Ponadto będzie działał w dokładnie taki sam sposób we wszystkich środowiskach (w Twoim komputerze, w serwerze działu QA, w serwerze produkcyjnym itd.). Natomiast wadą wirtualizacji jest to, że emulacja całego niezbędnego sprzętu i uruchamianie oddzielnego systemu operacyjnego dla każdej maszyny wirtualnej powoduje duże obciążenie w kategoriach poziomu użycia procesora, pamięci i czasu uruchamiania. Do zdefiniowania obrazów VM jako kodu możesz wykorzystać takie narzędzia jak Packer i Vagrant.

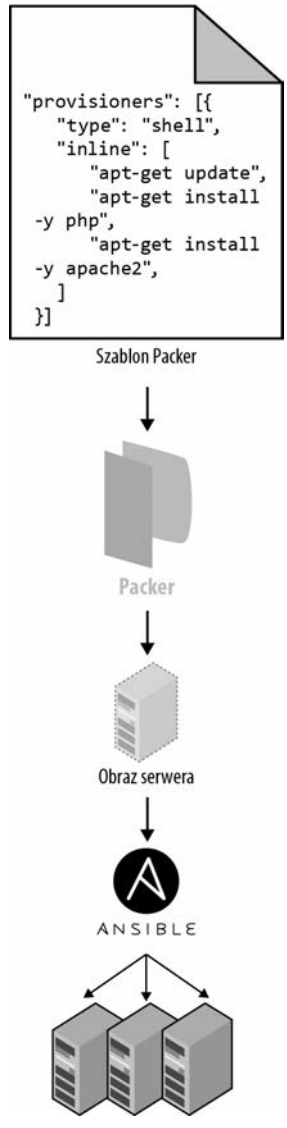

Rysunek 1.3. Narzędzie szablonu serwera, takie jak Packer, pozwala na utworzenie obrazu serwera. Następnie można wykorzystać inne narzędzia, takie jak Ansible, do zainstalowania tego obrazu we wszystkich serwerach

Kontenery

Kontener emuluje przestrzeń użytkownika systemu operacyjnego[2]. Uruchamiasz tzw. *silnik kontenera*, taki jak Docker, CoreOS rkt, cri-o, aby w ten sposób utworzyć odizolowane procesy, obszar pamięci, punkty montowania i sieć. Zaletą takiego podejścia jest to, że każdy kontener

[2] W większości nowoczesnych systemów operacyjnych kod działa w dwóch „przestrzeniach": *jądra* i *użytkownika*. Kod uruchomiony w przestrzeni jądra ma bezpośredni i niczym nieograniczony dostęp do całego urządzenia.

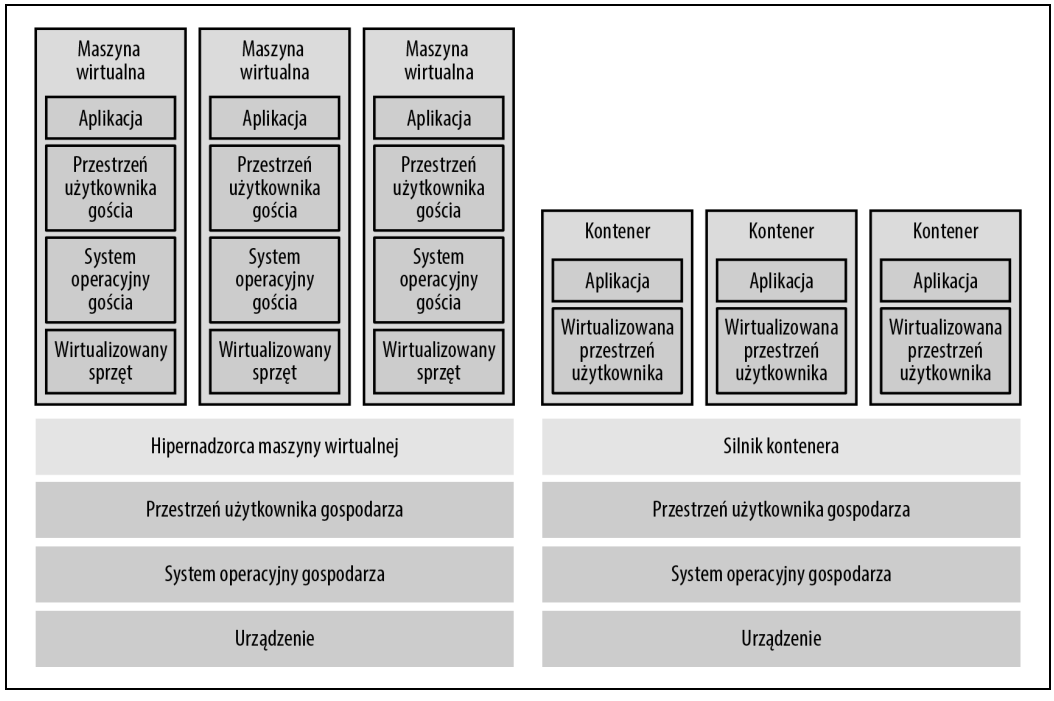

Rysunek 1.4. Dwa podstawowe rodzaje obrazów: maszyny wirtualne (po lewej) i kontenery (po prawej). Maszyna wirtualna przeprowadza wirtualizację sprzętu, natomiast kontener jedynie przestrzeni użytkownika

uruchomiony przez silnik kontenera ma dostęp jedynie do własnej przestrzeni użytkownika, więc pozostaje odizolowany od komputera gospodarza oraz pozostałych kontenerów. Ponadto kontener działa w dokładnie taki sam sposób we wszystkich środowiskach (w Twoim komputerze, w serwerze działu QA, w serwerze produkcyjnym itd.). Natomiast wadą tego podejścia jest to, że wszystkie kontenery działające w pojedynczym serwerze współdzielą sprzęt i jądro systemu operacyjnego, więc znacznie trudniej jest osiągnąć poziom izolacji i bezpieczeństwa oferowany przez maszyny wirtualne[3]. Jednak ze względu na współdzielenie jądra i zasobów sprzętowych uruchomienie kontenera może zabrać jedynie kilka milisekund, a sam kontener praktycznie

Nie zostały nałożone żadne ograniczenia w zakresie zabezpieczeń (tzn. można wykonać każdą instrukcję procesora, uzyskać dostęp do każdego miejsca na dysku twardym, zapisać dane w każdej komórce pamięci) i bezpieczeństwa (awaria w przestrzeni jądra najczęściej prowadzi do awarii całego komputera). Dlatego też przestrzeń jądra jest zwykle zarezerwowana dla działających na niskim poziomie, najbardziej zaufanych funkcji systemu operacyjnego (zazwyczaj nazywanych jądrem). Natomiast kod działający w przestrzeni użytkownika nie ma żadnego bezpośredniego dostępu do urządzenia i musi korzystać z API udostępnionego przez jądro systemu operacyjnego. Wspomniane API może wymuszać pewne ograniczenia zabezpieczeń (np. uprawnienia użytkownika) i bezpieczeństwa (np. awaria w przestrzeni użytkownika zwykle wpływa jedynie na daną aplikację) i dlatego praktycznie cały kod aplikacji jest uruchamiany w przestrzeni użytkownika.

[3] Ogólnie rzecz biorąc, kontenery zapewniają poziom izolacji wystarczający do uruchamiania własnego kodu. Jeżeli chcesz uruchamiać kod opracowany przez podmioty zewnętrzne (np. tworzysz własnego dostawcę chmury), który może aktywnie podejmować podejrzane działania, lepiej jest skorzystać z oferowanych przez maszyny wirtualne zalet większej izolacji.

nie stanowi żadnego obciążenia dla procesora i pamięci. Obrazy kontenerów jako kodu można zdefiniować za pomocą takich narzędzi jak Docker i CoreOS rkt.

Dla przykładu spójrz na szablon narzędzia Packer o nazwie *web-server.json*, tworzący tzw. obraz maszyny Amazon (ang. *amazon machine image*, AMI), czyli obraz maszyny wirtualnej możliwy do uruchomienia w chmurze AWS:

```
{
  "builders": [{
    "ami_name": "packer-example",
    "instance_type": "t2.micro",
    "region": "us-east-2",
    "type": "amazon-ebs",
    "source_ami": "ami-0c55b159cbfafe1f0",
    "ssh_username": "ubuntu"
  }],
  "provisioners": [{
    "type": "shell",
    "inline": [
      "sudo apt-get update",
      "sudo apt-get install -y php apache2",
      "sudo git clone https://github.com/brikis98/php-app.git /var/www/html/app"
    ],
    "environment_vars": [
      "DEBIAN_FRONTEND=noninteractive"
    ]
  }]
}
```

Ten szablon narzędzia Packer przeprowadza tę samą konfigurację serwera WWW Apache, którą wcześniej widziałeś w przykładzie *setup-webserver.sh*, używając tego samego kodu Bash[4]. Jedyna różnica między tym i poprzednim przykładem polega na tym, że szablon Packer nie uruchamia serwera WWW Apache (za pomocą wywołania `sudo service apache2 start`). To wynika z faktu stosowania szablonów zwykle do instalowania oprogramowania w obrazach, więc to oprogramowanie powinno działać właściwie tylko po uruchomieniu danego obrazu, np. przez wdrożenie go w serwerze.

Utworzenie obrazu AMI na podstawie tego szablonu odbywa się po wydaniu polecenia `packer build web server.json`. Po zakończeniu procesu tworzenia obrazu można go umieścić we wszystkich swoich serwerach AWS, skonfigurować każdy z nich do uruchomienia serwera WWW Apache po uruchomieniu serwera AWS (przykład takiego rozwiązania przedstawię w dalszej części rozdziału), a będą one działały w dokładnie taki sam sposób.

Warto w tym miejscu wspomnieć, że poszczególne narzędzia szablonów serwera mają nieco odmienne przeznaczenie. Packer jest zwykle używany do tworzenia obrazów działających na bazie serwerów produkcyjnych — przykładem może być pokazane tutaj utworzenie obrazu AMI dla konta produkcyjnego AWS. Narzędzie Vagrant jest zwykle używane do tworzenia obrazów działających w komputerach programistów, podobnie jak wykorzystujesz aplikację VirtualBox do tworzenia obrazów uruchamianych w swoim komputerze lokalnym działającym pod kontrolą systemu Linux, macOS lub Windows. Docker jest zwykle wykorzystywany do tworzenia obrazów poszczególnych aplikacji.

[4] Jako alternatywę dla Basha narzędzie Packer pozwala również na skonfigurowanie obrazów za pomocą narzędzia zarządzania konfiguracją, takiego jak Ansible lub Chef.

Kontenery Dockera mogą działać w komputerach produkcyjnych lub programistycznych, o ile inne narzędzie skonfigurowało ten komputer do pracy z Docker Engine. Przykładowo powszechnie stosowanym wzorcem jest utworzenie obrazu AMI wraz z zainstalowanym silnikiem Dockera, wdrożenie tego obrazu AMI w klastrze serwerów w ramach swojego konta AWS, a następnie wdrożenie poszczególnych kontenerów Dockera w klastrze, aby w ten sposób móc uruchamiać opracowane aplikacje.

Szablony serwerów to komponenty o znaczeniu kluczowym podczas przejścia do *infrastruktury niemodyfikowalnej*. Ta idea powstała na skutek zaczerpnięcia inspiracji z programowania funkcyjnego, w którym wartość zmiennej po jej zdefiniowaniu nigdy nie ulega zmianie. Jeżeli chcesz cokolwiek uaktualnić, tworzysz nową zmienną. Skoro zmienne nigdy się nie zmieniają, znacznie łatwiej jest uzasadnić potrzebę utworzenia danego fragmentu kodu.

Idea stojąca za infrastrukturą niezmienną jest podobna: po wdrożeniu serwera nigdy nie wprowadzasz w nim zmian. Jeżeli zachodzi potrzeba uaktualnienia czegokolwiek, np. wdrożenia nowej wersji kodu, tworzysz nowy obraz na podstawie szablonu serwera i wdrażasz go w nowym serwerze. Skoro serwer nigdy się nie zmienia, znacznie łatwiej jest uzasadnić potrzebę jego wdrożenia.

Narzędzia instrumentacji

Wprawdzie narzędzia szablonów serwera sprawdzają się doskonale podczas tworzenia maszyn wirtualnych i kontenerów, ale jak faktycznie można nimi zarządzać? W większości przypadków konieczne jest wykonanie przedstawionych tutaj zadań:

- Wdrażanie maszyn wirtualnych i kontenerów, co pozwala na efektywne wykorzystanie sprzętu.
- Przygotowanie uaktualnień dla istniejącej floty maszyn wirtualnych i kontenerów z wykorzystaniem strategii takich jak stałe wdrożenia, wdrożenia typu niebieski-zielony, a także tzw. *wdrożenie kanarkowe* (ang. *canary deployment*).
- Monitorowanie stanu maszyn wirtualnych i kontenerów oraz automatyczne zastępowanie uszkodzonych (*automatyczna naprawa*).
- Skalowanie liczby maszyn wirtualnych i kontenerów w górę lub w dół w zależności od obciążenia (automatyczne skalowanie).
- Rozkład ruchu między maszynami wirtualnymi i kontenerami (*mechanizm równoważenia obciążenia*).
- Umożliwienie maszynom wirtualnym i kontenerom wyszukiwania się w sieci i komunikowania poprzez nią (*usługa odkrywania*).

Obsługa tych zadań jest domeną *narzędzi instrumentacji*, takich jak Kubernetes, Marathon/Mesos, Amazon Elastic Container Service (Amazon ECS), Docker Swarm i Nomad. Przykładowo Kubernetes pozwala na zdefiniowanie sposobu zarządzania kontenerami Dockera jako kodem. Najpierw wdrażasz *klaster Kubernetes*, czyli grupę serwerów zarządzanych przez Kubernetes, a następnie używasz jej do uruchamiania kontenerów Dockera. Większość dostawców

chmury oferuje natywną obsługę w zakresie wdrażania zarządzanych klastrów Kubernetes, np. Amazon Elastic Container Service for Kubernetes (Amazon EKS), Google Kubernetes Engine (GKE) i Azure Kubernetes Service (AKS).

Jeśli masz działający klaster, w pliku YAML możesz zdefiniować sposób uruchamiania kontenera Dockera jako kodu.

```
apiVersion: apps/v1
# Użycie obiektu Deployment do wdrożenia wielu replik kontenerów
# Dockera oraz do deklaratywnego przekazywania im uaktualnień.
kind: Deployment

# Metadane dotyczące tego obiektu Deployment, m.in. nazwa.
metadata:
  name: example-app

# Specyfikacja konfigurująca dany obiekt Deployment.
spec:
  # Określenie sposobu wyszukiwania kontenerów przez ten obiekt Deployment.
  selector:
    matchLabels:
      app: example-app
  # Nakazanie obiektowi Deployment uruchomienie
  # trzech replik kontenerów Dockera.
  replicas: 3

  # Określenie sposobu uaktualniania obiektu Deployment. W omawianym przykładzie
  # zostało skonfigurowane nieustanne przekazywanie uaktualnień.
  strategy:
    rollingUpdate:
      maxSurge: 3
      maxUnavailable: 0
    type: RollingUpdate

  # To jest szablon dla wdrażanych kontenerów.
  template:

    # To są metadane dla kontenerów, m.in. etykiety.
    metadata:
      labels:
        app: example-app

    # Specyfikacja kontenera.
    spec:
      containers:

        # Uruchomienie serwera WWW Apache nasłuchującego na porcie 80.
        - name: example-app
          image: httpd:2.4.39
          ports:
            - containerPort: 80
```

Ten plik nakazuje Kubernetesowi utworzenie tzw. *obiektu Deployment*, czyli deklaratywnego rozwiązania pozwalającego na zdefiniowanie następujących kwestii:

- Jeden lub więcej kontenerów Dockera, które będą razem uruchamiane. Taka grupa kontenerów jest w Kubernetesie określana mianem *pod*. Zdefiniowany w tym fragmencie kodu pod zawiera jeden kontener Dockera, w którym jest uruchamiany serwer WWW Apache.
- Ustawienia dla każdego kontenera Dockera w podzie. W omawianym przykładzie pod konfiguruje serwer WWW Apache w taki sposób, aby nasłuchiwał na porcie 80.
- Liczba kopii (tzw. *replik*) poda uruchomionych w klastrze. W tym przykładzie zostały skonfigurowane trzy repliki. Kubernetes automatycznie ustala, gdzie w klastrze mają zostać wdrożone poszczególne pody, i wykorzystuje przy tym algorytm ustalający optymalny serwer w kategoriach wysokiej dostępności (np. chodzi o uruchamianie podów w oddzielnych serwerach, aby awaria jednego z nich nie doprowadziła do awarii całej aplikacji), zasobów (wybór serwera posiadającego dostępne porty, zasoby procesora, wolną pamięć lub inne zasoby wymagane przez kontener), wydajności (np. próba wybrania serwera o najmniejszym obciążeniu i najmniejszej liczbie kontenerów) itd. Kubernetes nieustannie monitoruje klaster, aby zagwarantować, że w każdej chwili są uruchomione trzy repliki, i automatycznie zastępować nowymi wszelkie pody, które uległy uszkodzeniu lub przestały udzielać odpowiedzi na żądania.
- Sposób wdrażania uaktualnień. Po wdrożeniu nowej wersji kontenera Dockera przedstawiony wcześniej kod będzie tworzył trzy nowe repliki, sprawdzi poprawność ich działania, a następnie usunie trzy stare repliki.

Ta niewielka liczba wierszy pliku YAML oferuje dość potężne możliwości! Wydanie polecenia `kubectl apply -f example-app.yml` nakazuje Kubernetesowi wdrożenie aplikacji. Później możesz wprowadzić zmiany w pliku YAML i ponownie wydać polecenie `kubectl apply`, aby zastosować uaktualnienie.

Narzędzia provisioningu

Podczas gdy zarządzanie konfiguracją, szablony serwera i narzędzia instrumentacji definiują kod przeznaczony do uruchomienia w każdym serwerze, *narzędzia provisioningu*, takie jak Terraform, CloudFormation i OpenStack Heat, są odpowiedzialne za utworzenie wspomnianych serwerów. Przy czym narzędzia provisioningu mogą nie tylko tworzyć serwery, ale również bazy danych, bufory, mechanizmy równoważenia obciążenia, kolejki, systemy monitorowania, konfiguracje podsieci, ustawienia zapory sieciowej, reguły routingu, certyfikaty SSL (ang. *secure socket layer*) i praktycznie każdy inny aspekt infrastruktury, jak pokazałem na rysunku 1.5.

Przedstawiony tutaj fragment kodu powoduje wdrożenie serwera WWW za pomocą Terraform.

```
resource "aws_instance" "app" {
  instance_type     = "t2.micro"
  availability_zone = "us-east-2a"
  ami               = "ami-0c55b159cbfafe1f0"

  user_data = <<-EOF
              #!/bin/bash
              sudo service apache2 start
              EOF
}
```

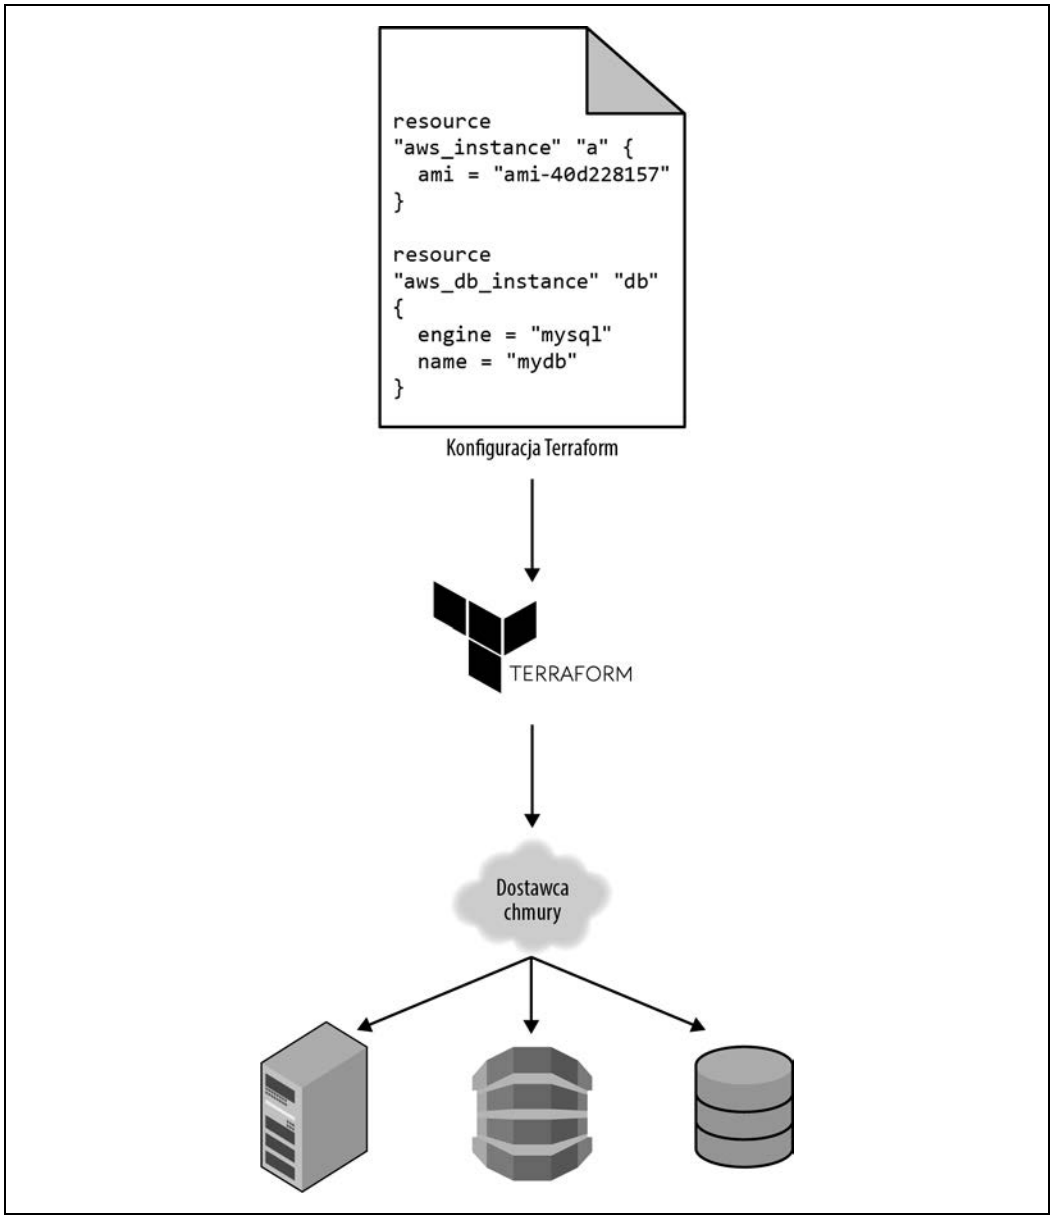

Rysunek 1.5. Narzędzia provisioningu wraz z dostawcą chmury pozwalają na tworzenie serwerów, baz danych, mechanizmów równoważenia obciążenia oraz wielu innych komponentów infrastruktury

Nie przejmuj się, jeśli nie znasz użytej składni. W tym momencie skoncentruj się na dwóch parametrach.

`ami`

Określa identyfikator obrazu AMI przeznaczonego do wdrożenia na serwerze. Temu parametrowi można przypisać wartość identyfikatora obrazu AMI utworzonego w poprzedniej

sekcji za pomocą narzędzia Packer i jego szablonu *web-server.json*, który zawierał kod dotyczący PHP, Apache i aplikacji.

`user_data`

To jest skrypt Bash wykonywany podczas uruchamiania serwera WWW. Omawiany przykład wykorzystuje ten kod do uruchomienia Apache.

Innymi słowy, w omawianym przykładzie pokazałem, jak narzędzia provisioningu i szablony serwera mogą ze sobą współdziałać, co jest często stosowanym wzorcem infrastruktury niemodyfikowalnej.

Korzyści płynące z infrastruktury jako kodu

Skoro poznałeś różne odmiany IaC, być może zastanawiasz się, po co to wszystko. Dlaczego miałbyś uczyć się nowych języków i narzędzi oraz tworzyć kolejny kod, którym będziesz musiał zarządzać?

Odpowiedzią jest to, że masz do czynienia z kodem o potężnych możliwościach. W zamian za inwestycję w postaci zmiany ręcznie wykonywanych zadań na kod bardzo zwiększają się Twoje możliwości w zakresie dostarczania oprogramowania. Zgodnie z 2016 State of DevOps Report (*https://puppet.com/resources/report/2016-state-devops-report/*) organizacje stosujące praktyki DevOps, np. podejście typu IaC, przeprowadzają wdrożenia 200-krotnie częściej, podnoszą się po awarii 24-krotnie szybciej, a czas realizacji w ich przypadku jest 2555-krotnie krótszy niż organizacji niestosujących praktyk DevOps.

Gdy infrastruktura jest zdefiniowana jako kod, można wykorzystać szeroką gamę praktyk tworzenia oprogramowania znacznie usprawniających proces jego dostarczania. Do tego procesu zaliczane są m.in.:

Samoobsługa

Wiele zespołów zajmujących się ręcznym wdrażaniem kodu ma małą liczbę administratorów systemu (często tylko jednego), którzy są jedynymi osobami znającymi magiczne zaklęcia pozwalające na zadziałanie wdrożenia i jako jedyni mają dostęp do środowiska produkcyjnego. To staje się poważnym wąskim gardłem wraz z rozwojem firmy. Jeżeli infrastruktura została zdefiniowana w kodzie, cały proces wdrożenia można zautomatyzować i pozwolić programistom na samodzielne wdrożenia, gdy będą do tego gotowi.

Szybkość i bezpieczeństwo

Po zautomatyzowaniu procesu wdrożenia stanie się on znacznie krótszy, ponieważ komputer jest w stanie wykonywać kroki wdrożenia zdecydowanie szybciej niż człowiek. Ponadto jest to bezpieczniejsze rozwiązanie, jeśli wziąć pod uwagę, że mamy do czynienia z zautomatyzowanym procesem, który jest spójniejszy, powtarzalny i niepodatny na błędy powstające na skutek ręcznego wykonywania zadań.

Dokumentacja

Zamiast zamknąć informacje o stanie infrastruktury w głowie jednego administratora systemu, stan infrastruktury można umieścić w plikach kodu źródłowego, które są czytelne dla każdego. Innymi słowy, podejście IaC działa w charakterze dokumentacji pozwalającej każdemu pracownikowi organizacji na poznanie sposobu działania procesu wdrożenia, nawet jeśli administrator systemu uda się na wakacje.

System kontroli wersji

Pliki kodu źródłowego w podejściu IaC można przechowywać w systemie kontroli wersji. W takim przypadku cała historia infrastruktury jest przechwycona w zapisie zdarzenia operacji przekazania danych do repozytorium (tzw. zatwierdzenia). To staje się narzędziem o potężnych możliwościach podczas debugowania, ponieważ po wystąpieniu problemu możesz zajrzeć do dziennika zdarzeń zatwierdzenia i ustalić, co zmieniło się w infrastrukturze. Drugim krokiem może być rozwiązanie problemu przez zwykłe przywrócenie kodu IaC do wcześniejszej wersji, o której wiadomo, że działa prawidłowo.

Sprawdzanie poprawności

Jeżeli stan infrastruktury został zdefiniowany w kodzie, podczas każdej zmiany można przeprowadzić analizę kodu, wykonać zestaw zautomatyzowanych testów, a także przekazać kod do narzędzi analizy statycznej — wszystkie te praktyki pozwalają na znaczne zmniejszenie ryzyka usterek kodu.

Wielokrotne użycie

Infrastrukturę można umieścić w modułach wielokrotnego użycia, więc zamiast przeprowadzać zupełnie od początku każde wdrożenie każdego produktu w każdym środowisku, możesz opierać się na doskonale znanych, udokumentowanych i przetestowanych w boju komponentach[5].

Szczęście

Jest jeszcze jeden bardzo ważny i zarazem często niedoceniany powód, dla którego powinieneś stosować podejście IaC: szczęście. Ręczne wdrażanie kodu i zarządzanie infrastrukturą jest nudne i żmudne. Programiści i administratorzy systemów nie lubią tego rodzaju zadań, ponieważ nie wiążą się one z kreatywnością, wyzwaniami, uznaniem itd. Możesz wdrożyć kod działający miesiącami bez zastrzeżeń i nikt tego nie dostrzeże — aż do dnia, w którym nabroisz. To tworzy stresogenne i nieprzyjazne środowisko. Podejście IaC oferuje lepszą alternatywę pozwalającą komputerowi na wykonywanie zadań, w których sprawdza się najlepiej (automatyzacja), a programistom również na robienie tego, w czym są najlepsi (tworzenie kodu).

Skoro dowiedziałeś się, skąd takie duże znaczenie podejścia IaC, kolejnym pytaniem może być, czy Terraform jest najlepszym dla Ciebie narzędziem IaC. Aby móc na nie odpowiedzieć, najpierw musisz zapoznać się z naprawdę krótkim wprowadzeniem do sposobu działania Terraform. Następnie przedstawię porównanie Terraform z innymi popularnymi rozwiązaniami w zakresie stosowania praktyk IaC, czyli Chef, Puppet i Ansible.

[5] Zajrzyj do przygotowanej przez Gruntwork biblioteki kodu stosującego podejście IaC (*https://gruntwork.io/infrastructure-as-code-library/*).

Jak działa Terraform?

Oto bardzo uogólniony opis sposobu działania Terraform: to narzędzie typu open source utworzone w języku Go przez HashiCorp. Kod Go jest kompilowany na postać pojedynczego pliku binarnego (zamiast po jednym pliku binarnym dla każdego obsługiwanego systemu operacyjnego) o nazwie, która nie powinna być zaskoczeniem: *terraform*.

Ten plik binarny można wykorzystać do wdrożenia infrastruktury z poziomu laptopa lub też utworzyć serwer czy inny komputer — i nie przejmować się przy tym żadną dodatkową infrastrukturą, która pozwoli na tę operację. To jest możliwe, ponieważ w tle plik binarny *terraform* wykonuje wywołania API w imieniu jednego dostawcy lub większej grupy *dostawców*, takich jak AWS, Azure, Google Cloud, DigitalOcean, OpenStack i wielu innych. To oznacza, że Terraform może wykorzystać infrastrukturę tych dostawców do obsługi własnych API serwerów, a także mechanizmów uwierzytelniania stosowanych wraz z tymi dostawcami (np. klucze API, które masz już dla dostawcy AWS).

Skąd Terraform wie, które wywołanie API ma zostać wykonane. Odpowiedź kryje się w tworzonych *konfiguracjach Terraform*, które są plikami tekstowymi określającymi infrastrukturę przeznaczoną do utworzenia. Wspomniane konfiguracje to „kod" w wyrażeniu „infrastruktura jako kod". Spójrz na przykładową konfigurację Terraform.

```
resource "aws_instance" "example" {
  ami           = "ami-0c55b159cbfafe1f0"
  instance_type = "t2.micro"
}

resource "google_dns_record_set" "a" {
  name         = "demo.google-example.com"
  managed_zone = "example-zone"
  type         = "A"
  ttl          = 300
  rrdatas      = [aws_instance.example.public_ip]
}
```

Nawet jeśli nigdy wcześniej nie widziałeś kodu Terraform, nie powinieneś mieć zbyt wielu problemów z ustaleniem sposobu jego działania. Ten fragment kodu nakazuje Terraform wykonanie wywołań API do AWS w celu wdrożenia serwera, a następnie wywołań API do Google Cloud w celu utworzenia wpisu DNS prowadzącego do adresu IP serwera w AWS. Mamy tutaj do czynienia z pojedynczą, prostą składnią (poznasz ją w rozdziale 2.) pozwalającą Terraform na wdrożenie powiązanych ze sobą zasobów między wieloma dostawcami chmury.

Całą infrastrukturę — serwery, bazy danych, mechanizm równoważenia obciążenia, topologię sieci itd. — możesz zdefiniować w plikach konfiguracyjnych Terraform, które następnie trafią do systemu kontroli wersji. Później, wydając polecenia takie jak `terraform apply`, przeprowadzasz wdrożenie tej infrastruktury. Plik binarny *terraform* przetwarza Twój kod, konwertuje go na serię wywołań API do dostawców chmury wymienionych w kodzie, a następnie w jak najefektywniejszy sposób wywołuje te API w Twoim imieniu, jak pokazałem na rysunku 1.6.

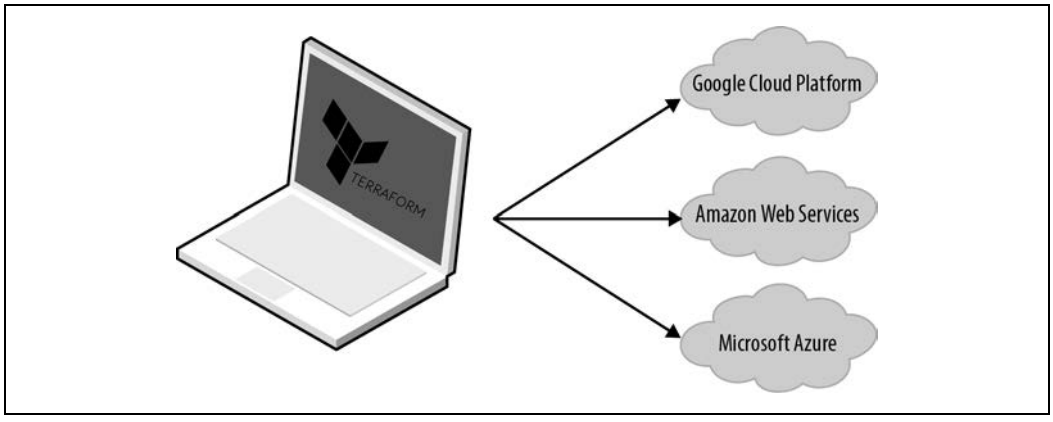

Rysunek 1.6. Terraform to plik binarny konwertujący zawartość plików konfiguracyjnych na wywołania API do dostawców chmury

Gdy ktokolwiek w zespole wprowadza zmiany w infrastrukturze, zamiast uaktualniać ją ręcznie i bezpośrednio w serwerze, zmiany nanosi w plikach konfiguracyjnych Terraform, weryfikuje je za pomocą zautomatyzowanych testów i analizy kodu, przekazuje uaktualniony kod do systemu kontroli wersji, a następnie wydaje polecenie `terraform apply` w celu zlecenia Terraform wykonania niezbędnych wywołań API i wdrożenia zmian.

Pełna przenośność między dostawcami chmury

Skoro Terraform obsługuje wielu różnych dostawców chmury, często pojawia się kwestia obsługi *pełnej przenośności* między nimi. Przykładowo, jeśli Terraform wykorzystałeś do zdefiniowania wielu serwerów, baz danych, mechanizmów równoważenia obciążenia i innych komponentów infrastruktury w AWS, czy możesz Terraform wydać polecenie wdrożenia tej samej infrastruktury u innego dostawcy chmury, np. Azure lub Google Cloud, za pomocą kilku kliknięć myszą?

To pytanie okazuje się być fałszywym tropem. Rzeczywistość jest taka, że nie można wdrożyć „dokładnie tej samej infrastruktury" u innego dostawcy chmury, ponieważ poszczególni dostawcy nie oferują dokładnie tych samych typów infrastruktury! Serwery, mechanizmy równoważenia obciążenia i bazy danych oferowane przez AWS różnią się od tych w Azure i Google Cloud pod względem funkcjonalności, konfiguracji, zarządzania, bezpieczeństwa, skalowalności, dostępności, możliwości monitorowania itd. Nie ma łatwego sposobu na „pełne" zniwelowanie tych różnic, zwłaszcza jeśli funkcjonalność dostępna u jednego dostawcy chmury często w ogóle nie istnieje u innych dostawców.

Podejście stosowane przez Terraform pozwala na tworzenie kodu przeznaczonego dla konkretnego dostawcy i wykorzystanie pełni oferowanych przez niego unikatowych możliwości, ale z użyciem tego samego języka, zestawu narzędzi i tych samych praktyk IaC, niezależnie od tego, dla którego dostawcy jest przeznaczony kod.

Porównanie Terraform z innymi narzędziami IaC

Infrastruktura jako kod jest wspaniała, ale proces wyboru narzędzia IaC już niekoniecznie. Funkcjonalność wielu narzędzi IaC nakłada się na siebie. Wiele z nich jest dostępnych jako oprogramowanie typu open source, choć równie dużo to produkty komercyjne. O ile wcześniej nie używałeś takiego narzędzia, prawdopodobnie nie wiesz, jakie kryteria zastosować przy wyborze narzędzia IaC.

Tę sytuację jeszcze bardziej utrudnia fakt, że większość dostępnych porównań narzędzi IaC ogranicza się do zaledwie przedstawienia listy ogólnych właściwości poszczególnych programów. Na jej podstawie można odnieść wrażenie, że każde narzędzie będzie dobre. Wprawdzie z technicznego punktu widzenia to prawda, ale te informacje nie okazują się zbyt pomocne. Można to porównać do stwierdzenia, że początkujący programista osiągnie sukces po utworzeniu witryny internetowej za pomocą języka PHP, C lub asemblera — pod względem technicznym to prawda, mimo to brakuje tutaj wielu informacji, które mają znaczenie podczas dokonywania wyboru.

W kolejnych sekcjach przedstawię dość dokładne porównanie najpopularniejszych narzędzi provisioningu i narzędzi przeznaczonych do zarządzania konfiguracją: Terraform, Chef, Puppet, Ansible, SaltStack, CloudFormation i OpenStack Heat. Moim celem jest umożliwienie Ci określenia, czy Terraform to dobry wybór. Mam zamiar to zrobić poprzez wyjaśnienie, dlaczego moja firma Gruntwork (*https://www.gruntwork.io/*) wybrała Terraform jako narzędzie IaC oraz, w pewnym sensie, dlaczego skłoniło mnie to do napisania tej książki[6]. Podobnie jak w przypadku wszelkich decyzji związanych z technologią, pod uwagę trzeba wziąć kompromisy i priorytety. Nawet jeśli Twoje priorytety będą inne niż moje, mam nadzieję, że omówieniem mojego procesu wyboru pomogę Ci w podjęciu decyzji.

Oto najważniejsze kompromisy, o których trzeba pamiętać:

- zarządzanie konfiguracją kontra provisioning,
- infrastruktura niemodyfikowalna kontra modyfikowalna,
- język proceduralny kontra deklaratywny,
- serwer główny kontra jego brak,
- agent kontra jego brak,
- duża społeczność kontra mała,
- rozwiązanie dojrzałe kontra najnowsze,
- używanie razem wielu narzędzi.

Zarządzanie konfiguracją kontra provisioning

Jak miałeś okazję zobaczyć wcześniej, Chef, Puppet, Ansible i SaltStack to narzędzia zarządzania konfiguracją, podczas gdy CloudFormation, Terraform i OpenStack Heat to narzędzia provisioningu. Wprawdzie granica między tymi typami narzędzi nie jest do końca wyraźnie ustalona, ale

[6] Docker, Packer i Kubernetes nie zostały uwzględnione w porównaniu, ponieważ te rozwiązania mogą być stosowane w połączeniu z dowolnymi narzędziami provisioningu i zarządzania konfiguracją.

biorąc pod uwagę to, że zwykle narzędzia konfiguracji mogą do pewnego stopnia zajmować się provisioningiem (np. Ansible pozwala na wdrożenie serwera), narzędzia provisioningu zaś pozwalają na przeprowadzanie konfiguracji (np. masz możliwość wykonywania skryptów konfiguracyjnych w serwerach przygotowanych przez Terraform), najczęściej wybierasz narzędzie najlepiej dopasowane do danej sytuacji[7].

W szczególności jeśli korzystasz z narzędzia szablonów serwera, np. Dockera lub Packera, odpada większość potrzeb związanych z zarządzaniem konfiguracją. Po utworzeniu obrazu na podstawie pliku *Dockerfile* lub szablonu Packer pozostało już tylko przygotowanie infrastruktury przeznaczonej do uruchamiania tych obrazów. Jeżeli chodzi o provisioning, najlepszym rozwiązaniem jest narzędzie provisioningu.

Zatem, jeśli nie używałeś narzędzi szablonów serwerów, dobrą alternatywą jest wspólne zastosowanie narzędzia konfiguracji i narzędzia provisioningu. Przykładowo Terraform możesz wykorzystać do przygotowania serwerów, które następnie skonfigurujesz za pomocą narzędzia Chef.

Infrastruktura niemodyfikowalna kontra modyfikowalna

Narzędzia konfiguracji takie jak Chef, Puppet, Ansible i SaltStack zwykle domyślnie stosują paradygmat infrastruktury niemodyfikowalnej. Przykładowo, jeśli nakażesz narzędziu Chef zainstalowanie nowej wersji OpenSSL, nastąpi uruchomienie procesu aktualizacji oprogramowania w istniejących serwerach i zmiany zostaną w nich wprowadzone. Wraz z upływem czasu i kolejnymi aktualizacjami każdy serwer ma unikatową historię zmian. W efekcie poszczególne serwery nieco się różnią od siebie, co prowadzi do powstawania drobnych błędów konfiguracji, które są trudne do zdiagnozowania i reprodukcji (to jest dokładnie ten sam problem związany ze zmianą konfiguracji jak w przypadku ręcznego zarządzania serwerami, choć zdecydowanie mniej kłopotliwy, gdy stosowane jest narzędzie zarządzania konfiguracją). Nawet po przeprowadzeniu zautomatyzowanych testów te błędy są trudne do wychwycenia — zmiana konfiguracji może działać świetnie w serwerze testowym, a nieco odmiennie w serwerze produkcyjnym, który ma zakumulowane miesiące uaktualnień nieodzwierciedlone w środowisku testowym.

Jeżeli narzędzia provisioningu, takiego jak Terraform, używasz do wdrażania obrazów utworzonych przez Dockera lub Packera, większość „zmian" to rzeczywiste wdrożenia zupełnie nowego serwera. Przykładowo, aby wdrożyć nową wersję OpenSSL, narzędzie Packer musisz wykorzystać do zbudowania obrazu wraz z nową wersją OpenSSL, wdrożyć ten obraz w nowych serwerach, a następnie zakończyć działanie starych serwerów. Skoro każde wdrożenie korzysta z niemodyfikowalnych obrazów nowych serwerów, takie podejście znacznie ogranicza ryzyko wprowadzenia błędów związanych ze zmianą konfiguracji, ponieważ dokładnie wiesz, jakie oprogramowanie działa w poszczególnych serwerach. Ponadto w każdej chwili bardzo łatwo możesz wdrożyć dowolną wcześniejszą wersję oprogramowania (tzn. dowolny z wcześniej utworzonych obrazów). Dzięki temu zautomatyzowane testy są znacznie efektywniejsze, ponieważ niemodyfikowalne obrazy zaliczające testy

[7] Obecnie granica między narzędziami konfiguracji i narzędziami provisioningu zaciera się jeszcze bardziej, ponieważ część najważniejszych narzędzi konfiguracji została znacznie usprawniona w zakresie obsługi provisioningu, przykładem mogą być tutaj Chef Provisioning (*https://web.archive.org/web/20190930010054/https://docs.chef.io/provisioning.html*) i Puppet AWS Module (*https://github.com/puppetlabs/puppetlabs-aws*).

w środowisku testowym niemal na pewno będą zachowywały się w dokładnie taki sam sposób w środowisku produkcyjnym.

Oczywiście istnieje możliwość wymuszenia na narzędziu zarządzania konfiguracją przeprowadzania niemodyfikowalnych wdrożeń. To jednak nie jest typowe podejście w takich narzędziach, natomiast jest naturalnym sposobem działania narzędzi provisioningu. Warto w tym miejscu wspomnieć, że podejście niemodyfikowalne również ma pewne wady. Przykładowo ponowne tworzenie obrazu na podstawie szablonu serwera i ponowne wdrażanie tego obrazu we wszystkich serwerach z powodu wprowadzenia drobnej zmiany może być niezwykle czasochłonne. Co więcej, niezmienność będzie trwała tylko do chwili faktycznego uruchomienia obrazu. Po przygotowaniu i uruchomieniu serwera rozpocznie on wprowadzanie zmian na dysku twardym, czego skutkiem będzie rozpoczęcie wprowadzania drobnych zmian konfiguracji (choć to można przezwyciężyć w przypadku częstych wdrożeń).

Język proceduralny kontra deklaratywny

Chef i Ansible zachęcają do stosowania stylu *proceduralnego*, w którym tworzysz kod określający krok po kroku, jak ma zostać osiągnięty oczekiwany stan końcowy. Terraform, CloudFormation, SaltStack, Puppet i OpenStack Heat zachęcają do stosowania stylu bardziej *deklaratywnego*, w którym tworzysz kod określający żądany stan końcowy, narzędzie pozwalające na stosowanie praktyk IaC zaś jest odpowiedzialne za znalezienie sposobu na przejście do tego stanu.

Aby pokazać różnicę między tymi podejściami, posłużę się przykładem. Wyobraź sobie, że chcesz wdrożyć 10 serwerów (*egzemplarze EC2* w AWS) przeznaczonych do uruchomienia obrazu AMI wraz z identyfikatorem `ami-0c55b159cbfafe1f0` (Ubuntu 18.04). Spójrz na uproszczony przykład szablonu Ansible pokazujący, jak osiągnąć żądany efekt za pomocą podejścia proceduralnego.

```
- ec2:
    count: 10
    image: ami-0c55b159cbfafe1f0
    instance_type: t2.micro
```

Oto uproszczony przykład konfiguracji Terraform wykonującej to samo zadanie, ale z zastosowaniem podejścia deklaratywnego:

```
resource "aws_instance" "example" {
  count         = 10
  ami           = "ami-0c55b159cbfafe1f0"
  instance_type = "t2.micro"
}
```

Na pierwszy rzut oka oba podejścia wyglądają podobnie, a po ich zastosowaniu za pomocą Ansible lub Terraform otrzymujemy podobny efekt. Interesujące jest to, co się stanie, gdy zachodzi potrzeba wprowadzenia zmiany.

Przykładowo przyjmujemy założenie o zwiększeniu się poziomu ruchu sieciowego, więc zachodzi potrzeba zwiększenia liczby serwerów do 15. W przypadku Ansible utworzony wcześniej kod proceduralny nie jest dłużej użyteczny — jeżeli zmienisz liczbę serwerów na 15 i ponownie wykonasz ten kod, nastąpi wdrożenie 15 nowych (kolejnych) serwerów, co razem daje 25 serwerów. Dlatego też musisz dokładnie wiedzieć, co zostało wcześniej wdrożone, i na tej podstawie utworzyć zupełnie nowy skrypt proceduralny, który będzie odpowiadał za dodanie pięciu nowych serwerów.

```
- ec2:
    count: 5
    image: ami-0c55b159cbfafe1f0
    instance_type: t2.micro
```

Natomiast w stylu deklaratywnym, skoro określasz oczekiwany stan końcowy, a Terraform szuka sposobu na jego otrzymanie, to Terraform odpowiada za ustalenie, jak zapewnić otrzymanie oczekiwanego stanu końcowego. Jeżeli chcesz wdrożyć 5 kolejnych serwerów, musisz jedynie powrócić do tej samej konfiguracji Terraform i zmienić liczbę serwerów z obecnych 10 na oczekiwane 15.

```
resource "aws_instance" "example" {
  count         = 15
  ami           = "ami-0c55b159cbfafe1f0"
  instance_type = "t2.micro"
}
```

Po zastosowaniu tej konfiguracji Terraform ustala, że wcześniej zostało utworzonych 10 serwerów, więc teraz trzeba utworzyć jedynie 5 nowych. Przed zastosowaniem nowej konfiguracji można skorzystać z polecenia `terraform plan` Terraform i sprawdzić, jakie zmiany zostaną wprowadzone.

```
$ terraform plan

# aws_instance.example[11] will be created
+ resource "aws_instance" "example" {
    + ami            = "ami-0c55b159cbfafe1f0"
    + instance_type  = "t2.micro"
    + (...)
  }

# aws_instance.example[12] will be created
+ resource "aws_instance" "example" {
    + ami            = "ami-0c55b159cbfafe1f0"
    + instance_type  = "t2.micro"
    + (...)
  }

# aws_instance.example[13] will be created
+ resource "aws_instance" "example" {
    + ami            = "ami-0c55b159cbfafe1f0"
    + instance_type  = "t2.micro"
    + (...)
  }

# aws_instance.example[14] will be created
+ resource "aws_instance" "example" {
    + ami            = "ami-0c55b159cbfafe1f0"
    + instance_type  = "t2.micro"
    + (...)
  }

Plan: 5 to add, 0 to change, 0 to destroy.
```

Co się stanie, gdy zajdzie potrzeba wdrożenia innej wersji aplikacji, np. obrazu AMI o identyfikatorze `ami-02bcbb802e03574ba`? W przypadku podejścia proceduralnego oba wcześniejsze szablony Ansible ponownie będą bezużyteczne, więc trzeba będzie przygotować kolejny szablon przeznaczony do wyśledzenia 10 wdrożonych wcześniej serwerów (a może to było 15 serwerów?) i ostrożnie

uaktualnić każdy z nich. Natomiast w przypadku podejścia deklaratywnego wracasz do dokładnie tego samego pliku konfiguracyjnego i zmieniasz parametr `ami` na `ami-02bcbb802e03574ba`:

```
resource "aws_instance" "example" {
  count         = 15
  ami           = "ami-02bcbb802e03574ba"
  instance_type = "t2.micro"
}
```

Oczywiście omawiane tutaj przykłady są bardzo uproszczone. Ansible pozwala na używanie tagów podczas wyszukiwania istniejących egzemplarzy EC2 przed wdrożeniem nowych (np. za pomocą parametrów `instance_tags` i `count_tag`). Jednak konieczność samodzielnego zajęcia się tego rodzaju logiką dla każdego zasobu zarządzanego przez Ansible, na podstawie wcześniejszej historii zasobu, może być zaskakująco skomplikowana — istniejące egzemplarze trzeba wyszukiwać nie tylko po tagach, ale również po wersji obrazu. To pokazuje dwa poważne problemy związane z proceduralnymi narzędziami stosującymi podejście IaC:

Kod proceduralny nie pozwala na pełne przechwycenie stanu infrastruktury

W omawianym przykładzie zapoznanie się z trzema utworzonymi wcześniej szablonami Ansible jest niewystarczające do ustalenia, co zostało wdrożone. Trzeba również znać *kolejność* wykonywania tych skryptów. Jeżeli zastosujesz je w innej kolejności, możesz otrzymać odmienną infrastrukturę i to jest coś, co nie będzie odzwierciedlone przez bazę kodu. Innymi słowy, musisz znać pełną historię każdej wcześniej wprowadzonej zmiany.

Kod proceduralny ogranicza możliwość jego wielokrotnego używania

Możliwość wielokrotnego użycia kodu proceduralnego jest znacznie ograniczona ze względu na konieczność uwzględnienia aktualnego stanu infrastruktury. Skoro ten stan nieustannie się zmienia, kod utworzony tydzień temu może być nieużyteczny, ponieważ został opracowany do zmiany już nieistniejącego stanu infrastruktury. W efekcie proceduralne bazy kodu mają tendencję do rozrastania się i zwiększania poziomu swojego skomplikowania wraz z upływem czasu.

Dzięki deklaratywnemu podejściu Terraform kod zawsze przedstawia aktualny stan infrastruktury. Na podstawie kodu od razu można ustalić, co aktualnie jest wdrożone, jak zostało skonfigurowane, i nie trzeba się przy tym przejmować np. historią tych wdrożeń. To niezwykle ułatwia tworzenie kodu wielokrotnego użycia, ponieważ nie trzeba ręcznie zajmować się uwzględnieniem aktualnego stanu. Zamiast tego można się skoncentrować na opisaniu żądanego stanu, a Terraform ustali, jak automatycznie przejść z jednego stanu do drugiego. W efekcie baza kodu Terraform zwykle pozostaje mała i łatwa do zrozumienia.

Oczywiście języki deklaratywne również mają swoje wady. Bez dostępu do pełnego języka programowania możliwości w zakresie wyrażania potrzeb są ograniczone. Przykładowo niektóre rodzaje zmian infrastruktury, takie jak wdrożenie bez przestoju, są trudne do wyrażenia w kategoriach czysto deklaratywnych (choć wcale nie niemożliwe, o czym przekonasz się podczas lektury rozdziału 5.). Podobnie ograniczone są możliwości w zakresie definiowania „logiki" (np. konstrukcje warunkowe typu `if`, pętle), tworzenie generycznego kodu wielokrotnego użycia może być trudne. Na szczęście Terraform oferuje pewną liczbę potężnych komponentów — takich jak zmienne danych wejściowych i wyjściowych, moduły, polecenia `create_before_destroy`, `count`, składnia trójargumentowa

i funkcje wbudowane — pozwalających na tworzenie przejrzystego, konfigurowalnego i modularnego kodu, nawet w języku deklaratywnym. Do tego tematu jeszcze wrócę w rozdziałach 4. i 5.

Serwer główny kontra jego brak

Domyślnie Chef, Puppet i SaltStack wymagają działania tzw. *serwera głównego* (ang. *master server*) przeznaczonego do przechowywania informacji o stanie infrastruktury i do przekazywania uaktualnień. Za każdym razem, gdy chcesz coś uaktualnić w infrastrukturze, używasz klienta (np. narzędzia działającego w powłoce) w celu wydania nowych poleceń do serwera głównego, który z kolei przekazuje uaktualnienia do wszystkich pozostałych serwerów — lub też te serwery regularnie pobierają uaktualnienia z serwera głównego.

Zastosowanie serwera głównego niesie wiele korzyści. Przede wszystkim to jest pojedyncze, centralne miejsce przeznaczone do analizy i zarządzania stanem infrastruktury. Wiele narzędzi zarządzania konfiguracją dostarcza nawet dla serwera głównego interfejs oparty na przeglądarce WWW (przykładami są tutaj Chef Console i Puppet Enterprise Console), ułatwiający sprawdzenie tego, co się dzieje we wdrożeniu. Ponadto część serwerów głównych nieustannie działa w tle i wymusza stosowanie danej konfiguracji. Dzięki temu, jeśli w serwerze zostanie ręcznie wprowadzona zmiana, serwer główny może ją wycofać i tym samym pomaga w uniknięciu wprowadzania zmian w konfiguracji.

Jednak wykorzystanie serwera głównego ma pewne poważne wady:

Dodatkowa infrastruktura

> Konieczność wdrożenia dodatkowego serwera lub nawet klastra takich serwerów (w celu zapewnienia wysokiej dostępności i skalowalności), aby móc uruchomić serwer główny.

Konieczność obsługi

> Trzeba pamiętać o obsłudze, uaktualnianiu, tworzeniu kopii zapasowej, monitorowaniu i skalowaniu serwera głównego.

Bezpieczeństwo

> Konieczne jest zapewnienie klientowi możliwości komunikacji z serwerem głównym, który z kolei musi mieć możliwości komunikowania się z pozostałymi serwerami. To najczęściej oznacza otworzenie dodatkowych portów i konfigurację dodatkowych systemów uwierzytelniania, co znowu zwiększa obszar dla potencjalnych ataków.

Chef, Puppet i SaltStack w różnym stopniu zapewniają obsługę węzłów pozbawionych serwera głównego, gdy oprogramowanie agenta wymienionych narzędzi działa w każdym serwerze, zwykle uruchamiane w ramach pewnego harmonogramu (np. zadanie cron wykonywane co pięć minut) używanego do pobierania najnowszych uaktualnień z systemu kontroli wersji (zamiast z serwera głównego). To znacznie zmniejsza liczbę elementów ruchomych, choć, jak dowiesz się z dalszej części rozdziału, jednocześnie zwiększa liczbę pytań pozostawionych bez odpowiedzi, zwłaszcza w zakresie przygotowywania serwerów i instalowania w nich oprogramowania agenta.

Ansible, CloudFormation, OpenStack Heat i Terraform domyślnie nie używają serwera głównego. Z technicznego punktu widzenia mogą opierać działanie na serwerze głównym, ale jest on częścią używanej infrastruktury, a nie oddzielnym serwerem wymagającym zarządzania. Przykładowo Terra-

form komunikuje się z dostawcami chmury za pomocą API dostawców chmury, więc w pewnym sensie te serwery API są serwerami głównymi, z wyjątkiem tego, że nie wymagają dodatkowej infrastruktury i mechanizmów uwierzytelniania (np. można wykorzystać własne klucze SSH). Ansible działa poprzez nawiązanie bezpośredniego połączenia z każdym serwerem poprzez SSH, więc nie wymaga żadnej dodatkowej infrastruktury lub mechanizmów uwierzytelniania (można wykorzystać własne klucze SSH).

Agent kontra jego brak

Chef, Puppet i SaltStack wymagają zainstalowania *oprogramowania agenta* (np. Chef Client, Puppet Agent, Salt Minion) w każdym serwerze, który ma zostać skonfigurowany. Agent zwykle działa w tle w każdym serwerze i jest odpowiedzialny za instalację najnowszych uaktualnień zarządzania konfiguracją.

Takie rozwiązanie również ma pewne wady:

Bootstrapping

W jaki sposób przygotować serwery i zainstalować w nich oprogramowanie agenta? Pewne narzędzia zarządzania konfiguracją mogą pomóc przy założeniu, że procesy dodatkowe zajmą się tym dla wspomnianych narzędzi (np. najpierw użyjesz Terraform do wdrożenia serwerów wraz z obrazem AMI zawierającym zainstalowanego agenta). Z kolei inne narzędzia konfiguracji mają specjalne procesy wymagające jednorazowego wydania poleceń w celu przygotowania serwerów z wykorzystaniem API dostawcy chmury i poprzez SSH zainstalowania w tych serwerach oprogramowania agenta.

Obsługa

Oprogramowanie agenta trzeba regularnie i ostrożnie uaktualniać i zwracać uwagę na zachowanie zgodności z serwerem głównym, o ile taki jest stosowany. Ponadto konieczne jest monitorowanie oprogramowania agenta i jego ponowne uruchamianie, jeśli ulegnie awarii.

Bezpieczeństwo

Jeżeli oprogramowanie agenta pobiera konfigurację z serwera głównego (lub innego serwera w przypadku nieużywania serwera głównego), konieczne jest otworzenie portów dla ruchu wychodzącego w każdym serwerze. Jeśli natomiast serwer główny przekazuje konfigurację do agenta, w każdym serwerze konieczne jest otworzenie portów dla ruchu przychodzącego. W obu przypadkach należy określić sposób uwierzytelnienia agenta w serwerze, z którym prowadzi komunikację, co z kolei zwiększa obszar dla potencjalnych ataków.

Także i w tym zakresie Chef, Puppet i SaltStack różnią się poziomem obsługi dla trybów pracy bez agenta (np. salt-ssh), ale należy mieć świadomość, że taki tryb nie zapewnia dostępu do pełnych możliwości narzędzia zarządzania konfiguracją. Dlatego też w rzeczywistych wdrożeniach domyślna konfiguracja dla Chef, Puppet i SaltStack niemal zawsze zawiera agenta i najczęściej również serwer główny, jak pokazałem na rysunku 1.7.

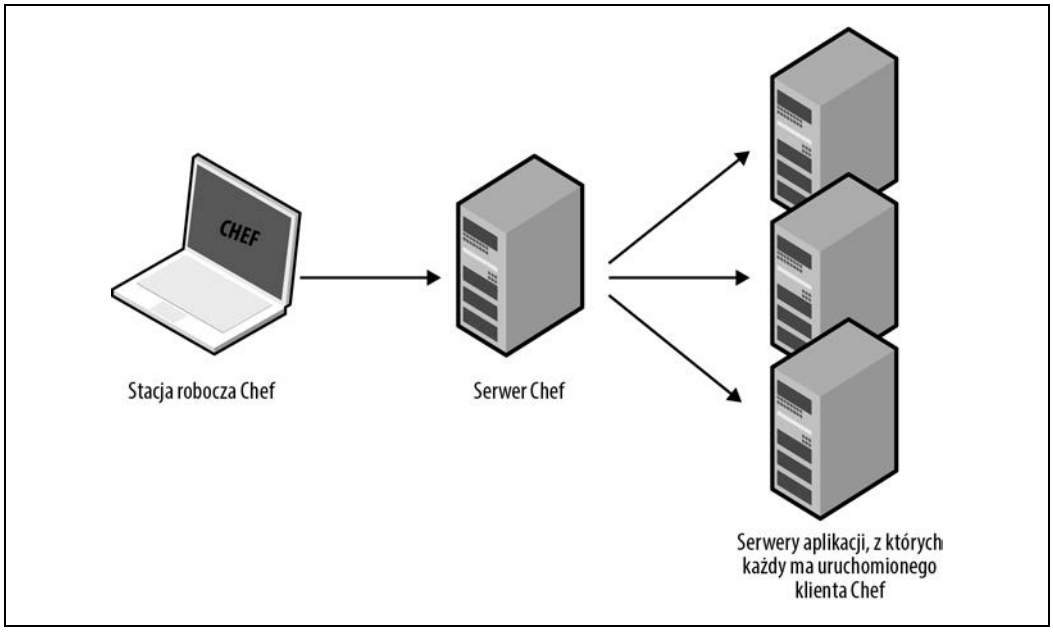

Rysunek 1.7. Typowa architektura Chef, Puppet i SaltStack opiera się na wielu ruchomych elementach. Przykładowo domyślna konfiguracja Chef oznacza uruchomienie w komputerze klienta Chef komunikującego się z serwerem głównym, który z kolei wdraża zmiany przez komunikowanie się z klientami Chef uruchomionymi we wszystkich pozostałych serwerach

Wszystkie te ruchome elementy wprowadzają do infrastruktury ogromną liczbę nowych trybów awarii. Za każdym razem, gdy o trzeciej nad ranem otrzymasz zgłoszenie błędu, musisz ustalić, czy to jest wynik błędu w kodzie aplikacji, czy w kodzie IaC, czy w kliencie zarządzania konfiguracją, czy w serwerze głównym, czy w trakcie komunikacji z serwerem głównym, czy w trakcie komunikacji innych serwerów z serwerem głównym, czy…

Ansible, CloudFormation, OpenStack Heat i Terraform nie wymagają instalacji żadnych dodatkowych agentów. A dokładnie to część z nich wymaga agentów, przy czym to oprogramowanie jest zwykle instalowane jako część używanej infrastruktury. Przykładowo AWS, Azure, Google Cloud i inni dostawcy chmury biorą na siebie instalację, zarządzanie i uwierzytelnianie oprogramowania agenta w każdym fizycznym serwerze. Jako użytkownik Terraform nie musisz się tym zajmować: wydajesz polecenia, a agent dostawcy chmury wykonuje je we wszystkich Twoich serwerach, jak możesz zobaczyć na rysunku 1.8. W przypadku Ansible konieczne jest uruchomienie demona SSH, który i tak działa w większości serwerów.

Duża społeczność kontra mała

Niezależnie od wybranej technologii wybierasz także społeczność. W wielu przypadkach ekosystem zbudowany wokół projektu może mieć ogromny wpływ na ocenę danej technologii, nawet większy niż jakość samej technologii. Społeczność określa liczbę osób pracujących nad projektem, liczbę dostępnych

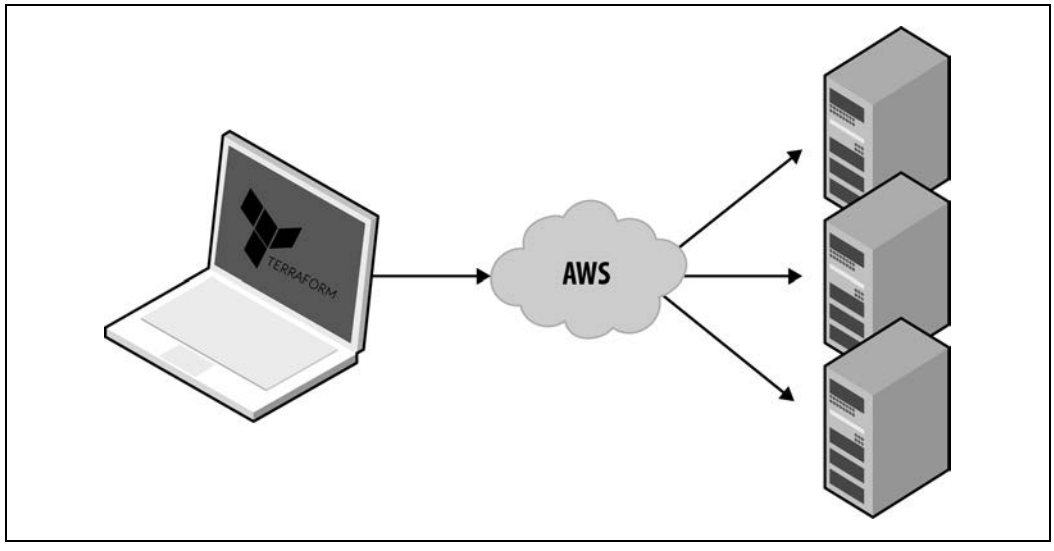

Rysunek 1.8. Terraform wykorzystuje architekturę opartą na agencie i pozbawioną serwera głównego. Potrzebujesz jedynie klienta Terraform, który zajmie się resztą, wykorzystując do tego API dostawcy chmury takiego jak AWS

wtyczek, możliwość integracji z rozwiązaniami oraz dostępność rozszerzeń, pomocy technicznej (np. blogi, pytania zadane w serwisach takich jak StackOverflow) i łatwość zatrudnienia osoby, która będzie mogła pomóc w rozwiązaniu problemu (np. pracownika, konsultanta, komercyjnej pomocy technicznej).

Bardzo trudno jest przeprowadzić dokładne porównanie społeczności, choć w internecie można znaleźć informacje o pewnych trendach. W tabeli 1.1 wymieniłem popularne i stosujące praktyki IaC narzędzia wraz z danymi, które zebrałem w maju 2019 roku. Te dane to m.in. rodzaj projektu (typu open source lub zamknięty kod źródłowy), obsługiwani dostawcy chmury, całkowita liczba osób pracujących nad projektem i gwiazdek zebranych przez projekt w serwisie GitHub, liczba operacji przekazania do repozytorium w ciągu ostatnich 30 dni, liczba aktywnych zgłoszeń w ciągu ostatnich 30 dni w okresie od połowy kwietnia do połowy maja, liczba bibliotek typu open source dostępnych dla narzędzia, liczba dotyczących danego narzędzia pytań zadanych w serwisie StackOverflow oraz liczba zamieszczonych w serwisie *https://pl.indeed.com/* ofert pracy, w których treści został wspomniany dany projekt[8].

[8] Większość tych danych — m.in. liczba osób pracujących nad projektem, gwiazdek, zmian i zgłoszeń — pochodzi z repozytoriów typu open source i narzędzi zgłaszania błędów (przede wszystkim GitHub) dla danego projektu. Ponieważ CloudFormation to rozwiązanie oparte na zamkniętym kodzie źródłowym, część tych informacji jest niedostępna.

Tabela 1.1. Porównanie społeczności wybranych narzędzi IaC

	Kod źródłowy	Chmura	Liczba pracujących nad projektem	Liczba gwiazdek	Liczba zatwierdzeń (ostatnie 30 dni)	Liczba błędów	Liczba bibliotek	Liczba pytań w serwisie StackOver ↪flow	Liczba ofert pracy
Chief	otwarty	wszystkie	562	5794	435	86	3832[a]	5982	4378[b]
Puppet	otwarty	wszystkie	515	5299	94	314[c]	6110[d]	3585	4200[e]
Ansible	otwarty	wszystkie	4386	37 161	506	523	20 677[f]	11 746	8787
SaltStack	otwarty	wszystkie	2237	9901	608	441	318[g]	1062	1622
Cloud ↪Formation	zamknięty	AWS	?	?	?	?	377[h]	3315	2318
Heat	otwarty	wszystkie	361	349	12	600[i]	0[j]	88	2201[k]
Terraform	otwarty	wszystkie	1261	16 827	173	204	1462[l]	2730	3641

[a] Liczba receptur dostępnych w Chef Supermarket (*https://supermarket.chef.io/cookbooks*).

[b] Aby uniknąć błędnych wyników dla wyrażenia *chef*, przeprowadziłem wyszukiwanie dla *chef devops*.

[c] Wartość na podstawie konta Puppet Labs JIRA (*https://tickets.puppetlabs.com/secure/Dashboard.jspa*).

[d] Liczba modułów w Puppet Forge (*https://forge.puppet.com/*).

[e] Aby uniknąć błędnych wyników dla wyrażenia *puppet*, przeprowadziłem wyszukiwanie dla *puppet devops*.

[f] Liczba wielokrotnego użycia ról w Ansible Galaxy (*https://galaxy.ansible.com/*).

[g] Liczba wzorów udostępnionych w koncie GitHub Salt Stack Formulas (*https://github.com/saltstack-formulas*).

[h] Liczba szablonów udostępnionych w koncie GitHub awslabs (*https://github.com/awslabs*).

[i] Wartość na podstawie narzędzia zgłaszania błędów OpenStack (*https://bugs.launchpad.net/openstack*).

[j] Nie byłem w stanie znaleźć żadnych kolekcji szablonów OpenStack Heat opracowanych przez społeczność.

[k] Aby uniknąć błędnych wyników dla wyrażenia *heat*, przeprowadziłem wyszukiwanie dla *openstack*.

[l] Liczba modułów w repozytorium Terraform Registry (*https://registry.terraform.io/*).

Oczywiście to nie jest doskonałe porównanie typu jeden do jednego. Przykładowo dla części narzędzi istnieje więcej niż tylko jedno repozytorium, a część korzysta z innych metod zgłaszania błędów i sugestii. Wyszukiwanie ofert pracy w języku angielskim, zawierających słowa *chef* i *puppet*, nie należy do łatwych zadań. Dla Terraform od 2017 roku istnieją oddzielne repozytoria dla kodu dostawców, więc pomiar aktywności na bazie jedynie repozytorium podstawowego daje znacznie zaniżony wynik (mniej więcej 10-krotnie) itd.

Mając to na względzie, warto zwrócić uwagę na kilka oczywistych trendów. Po pierwsze, poza CloudFormation wszystkie wymienione w tabeli narzędzia stosujące praktyki IaC są dostępne jako oprogramowanie typu open source i działają z wieloma dostawcami chmury. Po drugie, Ansible prowadzi w kategorii popularności, przy czym Salt i Terraform znajdują się tuż za nim.

Innym interesującym trendem, na który należy zwrócić uwagę, jest zmiana wartości wymienionych w tabeli względem tych, które przedstawiłem w pierwszym wydaniu książki. W tabeli 1.2 zaprezentowałem wyrażoną w procentach zmianę każdej wartości wobec tych, które zostały zebrane we wrześniu 2016 roku.

Tabela 1.2. *Zmiana wartości dotyczących społeczności wybranych narzędzi IaC dla danych zebranych między wrześniem 2016 roku i majem 2019 roku*

	Kod źródłowy	Chmura	Liczba pracujących nad projektem	Liczba gwiazdek	Liczba zatwierdzeń (ostatnie 30 dni)	Liczba błędów	Liczba bibliotek	Liczba pytań w serwisie Stack ↪Overflow	Liczba ofert pracy
Chief	otwarty	wszystkie	+18%	+31%	+139%	+48%	+26%	+43%	–22%
Puppet	otwarty	wszystkie	+19%	+27%	+19%	+42%	+38%	+36%	–19%
Ansible	otwarty	wszystkie	+195%	+97%	+49%	+66%	+157%	+223%	+125%
SaltStack	otwarty	wszystkie	+40%	+44%	+79%	+27%	+33%	+73%	+257%
Cloud ↪Formation	zamknięty	AWS	?	?	?	?	+57%	+441%	+249%
Heat	otwarty	wszystkie	+28%	+23%	–85%	+1566%	0	+69%	+2 957%
Terraform	otwarty	wszystkie	+93%	+194%	–61%	–58%	+3555%	+1984%	+8 288%

Dane zamieszczone w tabeli 1.2 również nie są doskonałe, ale wystarczające do tego, aby dostrzec trend: Terraform i Ansible zyskują ogromną popularność. Wzrost liczby osób pracujących nad tymi projektami, otrzymanych gwiazdek, istniejących dla nich bibliotek typu open source, pytań zadanych w serwisie StackOverflow oraz ofert pracy jest po prostu oszałamiający[9]. Oba wymienione narzędzia mogą się pochwalić ogromnymi, aktywnymi społecznościami i na podstawie tego trendu można przyjąć założenie, że w przyszłości staną się one jeszcze większe.

Rozwiązanie dojrzałe kontra najnowsze

Kolejnym kluczowym czynnikiem przy wyborze technologii jest jej dojrzałość.

W tabeli 1.3 wymieniłem daty wydania i obecne numery wersji poszczególnych narzędzi stosujących praktyki IaC, analizowanych w tym podrozdziale (stan na maj 2019 roku).

To również nie jest dokładne porównanie, ponieważ poszczególne narzędzia stosują odmienne schematy wersjonowania. Mimo to trendy powinny być wyraźnie widoczne. Jak dotąd Terraform jest najmłodszym narzędziem IaC w tym porównaniu. Ponieważ nadal znajduje się w wersji wcześniejszej niż 1.0.0, nie ma gwarancji stabilności i wstecznej zgodności API, a błędy pojawiają się dość często (na szczęście większość z nich to drobiazgi). To jest największa wada Terraform: wprawdzie w krótkim okresie stało się niezwykle popularne, ale ceną, którą trzeba zapłacić za korzystanie z nowego narzędzia, jest to, że nie zostało jeszcze tak dopracowane jak inne opcje IaC.

[9] Spadek liczby zatwierdzeń w systemie kontroli wersji i liczby zgłoszeń wynika wyłącznie z tego, że podana wartość dotyczy jedynie podstawowego repozytorium Terraform. W 2017 roku kod przeznaczony do obsługi dostawców został przeniesiony do oddzielnych repozytoriów, więc ogromna aktywność w tych ponad 100 repozytoriach nie została uwzględniona w tabeli.

Tabela 1.3. *Porównanie dojrzałości wybranych narzędzi IaC w maju 2019 roku*

	Pierwsze wydanie	Obecne wydanie
Puppet	2005	6.0.9
Chef	2009	12.19
CloudFormation	2011	???
SaltStack	2011	2019.2.0
Ansible	2012	2.5.5
Heat	2012	12.0.0
Terraform	2014	0.12.0

Używanie razem wielu narzędzi

Wprawdzie w rozdziale porównywałem narzędzia IaC, ale rzeczywistość jest taka, że prawdopodobnie będziesz korzystać z wielu narzędzi podczas tworzenia infrastruktury. Każde z nich ma zalety i wady, więc do Ciebie należy wybór odpowiedniego narzędzia do wykonania konkretnego zadania.

W tej sekcji przedstawiam trzy często spotykane połączenia, z którymi zetknąłem się podczas pracy dla różnych firm.

Provisioning plus zarządzanie konfiguracją

Przykład: Terraform i Ansible. Terraform wykorzystujesz do wdrażania całej infrastruktury łącznie z topologią sieci (wirtualna prywatna chmura (ang. *virtual private cloud*, VPC), podmaski, tabele routingu), magazynami danych (np. MySQL, Redis), mechanizmami równoważenia obciążenia oraz serwerami. Następnie używasz Ansible do wdrożenia aplikacji w tych serwerach, jak pokazałem na rysunku 1.9.

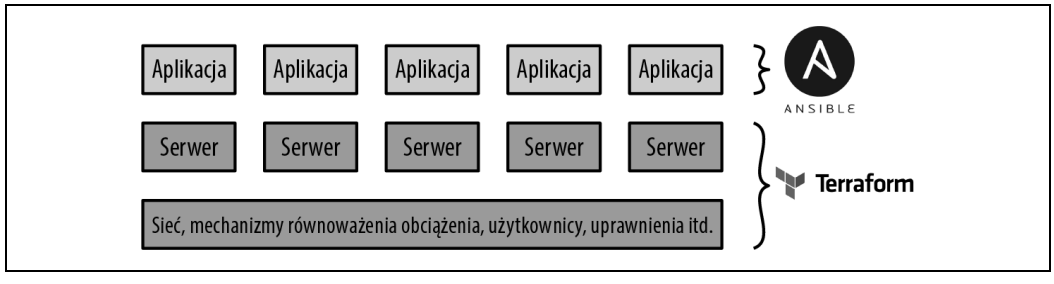

Rysunek 1.9. Używanie razem narzędzi Terraform i Ansible

To jest łatwe rozwiązanie na początek, ponieważ nie wymaga dodatkowej infrastruktury (Terraform i Ansible to aplikacje działające jedynie po stronie klienta) i istnieje wiele sposobów na zapewnienie współpracy między Ansible i Terraform (np. Terraform dodaje specjalne znaczniki do serwerów, które z kolei Ansible wykorzystuje do odszukania danego serwera i jego skonfigurowania). Wadą tego połączenia są tworzenie dużej ilości kodu proceduralnego i modyfikowalne serwery, więc wraz ze wzrostem bazy kodu, infrastruktury i zespołu obsługa całości staje się coraz trudniejsza.

Provisioning plus szablony serwerów

Przykład: Terraform i Packer. Narzędzia Packer używasz do przygotowania aplikacji w postaci obrazu maszyny wirtualnej. Następnie wykorzystujesz Terraform do wdrożenia (a) serwerów za pomocą wspomnianych obrazów maszyn wirtualnych i (b) pozostałej części infrastruktury, łącznie z topologią sieci (VPC, podmaski, tabele routingu), magazynami danych (np. MySQL, Redis) oraz mechanizmami równoważenia obciążenia, jak pokazałem na rysunku 1.10.

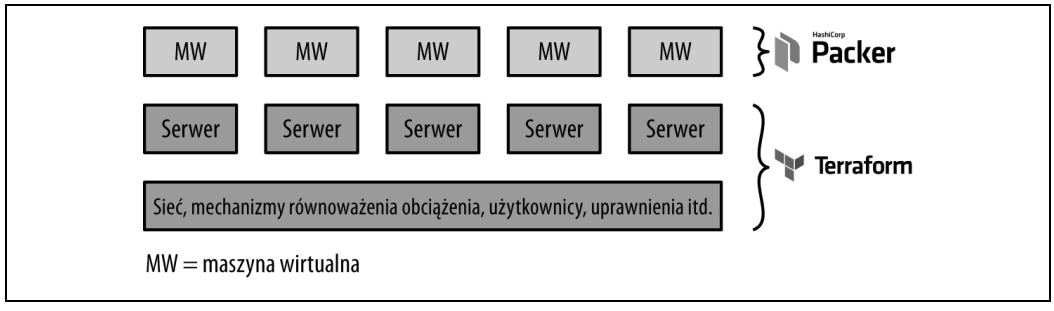

Rysunek 1.10. Używanie razem narzędzi Terraform i Packer

To również jest łatwe rozwiąznie na początek, ponieważ nie wymaga dodatkowej infrastruktury (Terraform i Packer to aplikacje działające jedynie po stronie klienta) i w dalszej części książki nabędziesz dużej wprawy we wdrażaniu obrazów maszyn wirtualnych za pomocą Terraform. Co więcej, to jest podejście infrastruktury niemodyfikowalnej, co znacznie ułatwia późniejszą obsługę. Jednak i to połączenie ma pewne wady. Pierwsza polega na tym, że przygotowanie i wdrożenie maszyny wirtualnej może trwać bardzo długo, co zmniejsza liczbę przeprowadzanych wdrożeń. Druga, jak się dowiesz z dalszych rozdziałów książki, jest taka, że strategie wdrażania możliwe do implementacji za pomocą Terraform są ograniczone (nie możesz natywnie zastosować wdrożenia typu niebieski-zielony). Dlatego skutkiem będzie tworzenie ogromnej liczby skomplikowanych skryptów wdrożenia lub zwrócenie się ku narzędziom instrumentacji, co przedstawię w następnym punkcie.

Provisioning plus szablony serwerów plus instrumentacja

Przykład: Terraform, Packer, Docker i Kubernetes. Narzędzia Packer używasz do przygotowania obrazu maszyny wirtualnej zawierającej zainstalowane narzędzia Docker i Kubernetes. Następnie wykorzystujesz Terraform do wdrożenia (a) klastra serwerów, z których każdy będzie uruchamiał wspomniany obraz maszyny wirtualnej, i (b) pozostałej części infrastruktury, łącznie z topologią sieci (VPC, podmaski, tabele routingu), magazynami danych (np. MySQL, Redis) oraz mechanizmami równoważenia obciążenia. Na końcu, po uruchomieniu klastra serwerów, nastąpi przygotowanie klastra Kubernetes, który będzie można wykorzystać do uruchamiania i zarządzania aplikacjami Dockera, jak pokazałem na rysunku 1.11.

Zaletą takiego podejścia jest to, że obrazy Dockera są tworzone dość szybko, można je uruchamiać i testować w komputerze lokalnym oraz wykorzystać wszystkie zalety wbudowanej funkcjonalności Kubernetes, m.in. stosowanie różnych strategii wdrażania, automatyczną naprawę, automatyczne skalowanie itd. Wadą tego połączenia jest większy poziom skomplikowania, zarówno w kategoriach

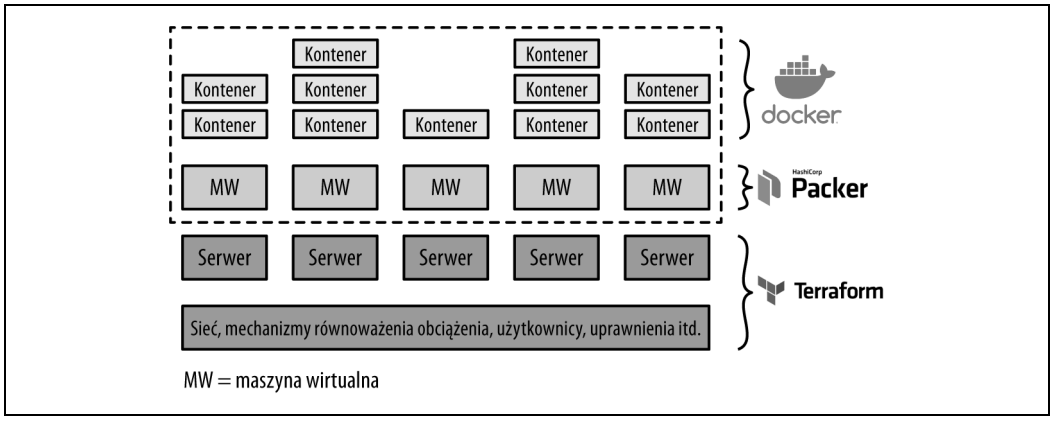

Rysunek 1.11. Używanie razem narzędzi Terraform, Packer, Docker i Kubernetes

dodatkowej infrastruktury przeznaczonej do uruchomienia rozwiązania (klastry Kubernetes są kosztowne i trudne do wdrożenia i działania, choć większość najważniejszych dostawców chmury oferuje teraz zarządzane usługi Kubernetes, co może odciążyć Cię od pewnych zadań), jak i w kategoriach poznawania, zarządzania i debugowania rozwiązania.

Podsumowanie

Po połączeniu wszystkiego w całość w tabeli 1.4 wymieniłem najpopularniejsze narzędzia stosujące praktyki IaC. Zwróć uwagę, że ta tabela pokazuje *domyślny* lub *najczęściej stosowany* sposób, w jaki są używane te narzędzia IaC. Jak wspomniałem we wcześniejszej części rozdziału, te narzędzia IaC są na tyle elastyczne, że mogą być używane także w innych konfiguracjach (np. Chef bez serwera głównego, Salt do przygotowania infrastruktury niemodyfikowalnej itd.).

W firmie Gruntwork chcieliśmy zastosować rozwiązanie typu open source, niezależne od chmury narzędzie provisioningu zapewniające obsługę infrastruktury niemodyfikowalnej, język deklaratywny, architekturę pozbawioną serwera głównego i agenta, a także charakteryzującą się dużą społecznością i dojrzałą bazą kodu. Z tabeli 1.4 wynika, że choć Terraform nie jest perfekcyjnym rozwiązaniem, to najlepiej spełnia postawione przez nas wymagania.

Czy Terraform spełnia również Twoje kryteria? Jeśli tak, przejdź do rozdziału 2., z którego dowiesz się, jak można korzystać z Terraform.

Tabela 1.4. Porównanie najczęściej stosowanego sposobu użycia popularnych narzędzi IaC

	Kod źródłowy	Chmura	Typ	Infrastruktura	Język	Agent	Serwer główny	Społeczność	Dojrzałość
Chef	otwarty	wszystkie	konfiguracja zarządzania	zmienna	proceduralny	tak	tak	duża	wysoka
Puppet	otwarty	wszystkie	konfiguracja zarządzania	zmienna	deklaratywny	tak	tak	duża	wysoka
Ansible	otwarty	wszystkie	konfiguracja zarządzania	zmienna	proceduralny	nie	nie	olbrzymia	średnia
SaltStack	otwarty	wszystkie	konfiguracja zarządzania	zmienna	deklaratywny	tak	tak	duża	średnia
CloudFormation	zamknięty	AWS	provisioning	niezmienna	deklaratywny	nie	nie	mała	średnia
Heat	otwarty	wszystkie	provisioning	niezmienna	deklaratywny	nie	nie	mała	niska
Terraform	otwarty	wszystkie	provisioning	niezmienna	deklaratywny	nie	nie	olbrzymia	niska

Infrastruktura: koduj, wdrażaj i zarządzaj!

Terraform jest narzędziem open source służącym do tworzenia i wdrażania kodu infrastruktury licznych platform wizualizacji i chmury, takich jak Amazon Web Services, Google Cloud, Azure, oraz zarządzania tym kodem. Migracja korporacyjnych systemów IT do chmury jest niezwykle obiecującą możliwością i wielu menedżerów wysokiego szczebla dostrzega zalety technologii chmurowych. Terraform znakomicie ułatwia wdrażanie rozwiązań opartych na chmurze, jest też narzędziem szczególnie predysponowanym do pracy zgodnej z metodyką DevOps, dzięki której współdziałanie ludzi, procesów i technologii pozwala na zapewnienie wysokiej jakości i niezawodności produktu.

Ta książka jest drugim, wzbogaconym i uzupełnionym wydaniem praktycznego samouczka, dzięki któremu rozpoczęcie pracy z Terraform stanie się bardzo łatwe. Zapoznasz się z językiem programowania Terraform i zasadami tworzenia kodu. Szybko zaczniesz go wdrażać oraz zarządzać infrastrukturą za pomocą zaledwie kilku poleceń. Istotną częścią publikacji jest ukazanie metodologii DevOps w działaniu oraz wyjaśnienie zasad kodowania infrastruktury. Dziesiątki jasnych przykładów kodu, które można samodzielnie wypróbować w akcji, ułatwią zrozumienie podstaw. Niezależnie od tego, czy jesteś początkującym programistą, weteranem DevOps lub doświadczonym administratorem systemów, szybko przejdziesz od podstaw Terraform do przygotowania pełnego stosu, który zapewni obsługę ogromnego ruchu sieciowego i dużych zespołów programistów.

W książce między innymi:

- wprowadzenie do Terraform wraz ze zmianami w kolejnych wydaniach
- tworzenie wysokiej jakości modułów Terraform
- ręczne i zautomatyzowane testy kodu
- wdrażanie klastrów serwerów, mechanizmy równoważenia obciążenia i bazy danych
- zarządzanie informacjami o stanie infrastruktury
- zaawansowana składnia Terraform

Yevgeniy Brinkman jest pasjonatem programowania i tworzenia publikacji dotyczących tworzeniu kodu. Zafascynowany możliwościami, jakie daje DevOps, współzałożył firmę Gruntwork, która pomaga innym przedsiębiorstwom we wdrożeniu tej metodyki. Wcześniej pracował jako inżynier oprogramowania dla takich tuzów jak LinkedLn, TripAdvisor, Cisco Systems i Thomson Financial.

Helion
helion.pl
HELION SA
ul. Kościuszki 1c
44-100 Gliwice
tel.: 32 230 98 63
helion@helion.pl

KOD KORZYŚCI
Sięgnij po więcej!
ISBN 978-83-283-6649-7
9 788328 366497
INFORMATYKA W NAJLEPSZYM WYDANIU
Cena: 69,00 zł