

# CLOUDGEN: Bulut Bilişim Sistemlerinin Başarım Değerlendirmesi için İş Yükü Üretimi

## CLOUDGEN: Workload Generation for the Evaluation of Cloud Computing Systems

Furkan Koltuk<sup>\*†</sup>, Alper Yazar<sup>\*†</sup>, Ece Güran Schmidt<sup>†</sup>

<sup>†</sup> Elektrik Elektronik Mühendisliği Bölümü, ODTÜ, Ankara, Türkiye  
{furkan.koltuk, alper.yazar, eguran}@metu.edu.tr

<sup>\*</sup> Savunma Sistem Teknolojileri, ASELSAN A.Ş., Ankara, Türkiye  
{fkoltuk, ayazar}@aselsan.com.tr

**Özetçe** —Bu bildiriye bulut bilişim sistemlerinde kaynak yönetimi yaklaşımlarının değerlendirilebilmesi amacıyla Altyapı ve Platform servisleri için sentetik iş yükleri üreten bir iş akışı olan CLOUDGEN önerilmektedir. CLOUDGEN verilen bir izdeki kayıtları sistematik olarak işlemekte, gruplamakta ve bu gruplara farklı iş yükü parametreleri için dağılımlar uydurmaktadır. Gruplama sanal makine tipleri elde edecek şekilde yapılarak literatürdeki yazılım servislerine yönelik iş yükü çalışmalarından farklı şekilde Altyapı ve Platform servislerine uygun izler üretmeye uygun modeller oluşturulmuştur. CLOUDGEN kullanılarak yakın tarihli Azure izi parametreleri araştırmacılar tarafından kullanılabilir şekilde açık olarak modellenmiş ve bu model kullanılarak istatistiksel benzerlikte sentetik izler yaratılmıştır.

**Anahtar Kelimeler**—İş yükü yaratma, dağılım uydurma, bulut bilişim

**Abstract**—In this paper, we propose CLOUDGEN workflow that produces synthetic workloads for Infrastructure and Platform as a Service for the evaluation of resource management approaches in cloud computing systems. To this end, CLOUDGEN systematically processes and clusters records in a given workload trace and fits distributions for different workload parameters within the clusters. Different than the previous work, clustering is carried out to produce different virtual machine types for achieving models that are suitable for producing Infrastructure and Platform as a Service workload models. Finally, we demonstrate CLOUDGEN by modeling recent Azure traces with enough detail to enable researchers to use these models and generating synthetic traces that are statistically similar to the Azure traces.

**Keywords**—Workload generation, distribution fitting, cloud computing

### I. GİRİŞ

Bulut bilişim, bilgi işlem kaynaklarının Altyapı (Infrastructure as a Service-IaaS), Platform (Platform as a Service-PaaS) ve Yazılım (Infrastructure as a Service-SaaS) seviyesinde servisler olarak kullanıcılara sunulmasıdır. IaaS/PaaS servislerinde işlemci, bellek, disk ve ağ gibi kaynaklar kullanıcıların istekleri doğrultusunda oluşturulan sanal makinelere (Virtual

Machine - VM) atanır. Bulut kaynak yönetimi bu atamaların yüksek başarımı ve verimli olarak yapılmasını sağlar.

Farklı fiziksel bulut konfigürasyonlarının ve yeni kaynak yönetimi yaklaşımlarının düşük maliyetle ve hızlı test edilebilmesi için simülasyon yöntemleri kullanılmaktadır [1]. Gerçeğe yakın sonuçlar alabilmek için simülasyon aracına gerçekçi kullanıcı isteklerini içeren iş yükü (workload) girdileri vermek gerekmektedir. Bu iş yükü gerçek bir iz (trace) olabileceği gibi bu izler kullanılarak oluşturulan bir model yolu ile de üretilebilir.

Model tabanlı iş yükü üretimi ile hem gerçeğe yakın hem de farklı durumları canlandırabilmek için ayarlanabilen sentetik izler oluşturulabilir. Bu şekilde deneyler benzer istatistiksel özellikler taşıyan farklı sentetik izlerle tekrarlanabilir, daha genel sonuçlara ulaşılabilir ve aşırı uyum gösteren (overfitting) durumlardan kaçınılabilir. Modellerden çıkarılabilecek özellikler ve ilişkiler kaynak yönetiminde kullanılarak daha iyi ayarlanmış yaklaşımlar oluşturulabilir.

Bu bildiriye, verilen bir sanal makine-tabanlı bulut iş yükü izinden modeller üreten ve buna bağlı olarak VM istekleri şeklinde gerçekçi IPaaS (IaaS veya PaaS) iş yükleri üretimini mümkün kılan CLOUDGEN iş akışı (workflow) önerilmektedir. CLOUDGEN iş yükü modeli literatürdeki son izlerden biri olan, 2016'da alınmış ve anonim hale getirilmiş Azure sanal makine iş yükü izi ile [2] üretilmiştir. CLOUDGEN, literatürde sanal makine tabanlı IPaaS iş yüklerini modellemeye yönelik ve güncel bir izi modelleyen ilk çalışmalardan biridir.

### II. ÖNCEKİ ÇALIŞMALAR

Bulut iş yükü üretimi hakkındaki çalışmalar çoğunlukla uygulama ve iş odaklıdır. [3]'te yazarlar Hadoop iş özelliklerinin iş varış zamanları arası (job interarrival times), girdi büyüklükleri ve veri oranlarının dağılımları için 1., 25., 50., 75. ve 99. yüzdeliklikleri hesaplayarak dağılımlara yaklaşır ve örnekleme yaparak iş yükü oluşturmayı öne sürerler. [4]'ün yazarları 2011'de yayınlanan Google bulut izlerinin ikinci sürümünü dağılım analizleri ve gruplama (clustering) yolu ile modelleyerek sentetik iş yükleri oluşturmuştur. [5]'in yazarları benzer şekilde dağılım analizleri kullanarak Web tabanlı bir iş

yükü modellemesi sağlamıştır. Ancak, bu çalışmaların hiçbiri sanal makine-tabanlı iş yüklerini ele almamaktadır. Bilinen en güncel sanal makine-tabanlı iş yükü izi [6]'nın yazarlarınca yayınlanmış ve bu iz aynı çalışmada kaynak kullanımı tahmini amaçlı ele alınmış fakat yeniden üretilebilir bir iş yükü modeli çıkarılmamıştır. [7]'nin yazarları çalışmalarında [4]'te sunulan benzer bir yaklaşım kullanarak Amazon Web Services'in sağladığı bir sanal özel bulut'a (Virtual Private Cloud) ait 14 aylık bir iş yükünü modellemiştir, ancak metrik olarak kaynak kullanım (resource utilization) oranları kullanılmıştır.

### III. CLOUDGEN

#### A. Yöntem

İş yükü modeli oluşturulacak bir iz [8]'e göre gerçek bir iş yükünü temsil etmeli ve izdeki iş yükü karakteristiği zaman içerisinde değişken olmamalıdır. [2] iş yükü izi yeni tarihli bir izdir ve [6]'da iş yükü analizi ve gelecek iş yükü tahmini için kullanılmıştır. Buna uygun olarak [2] iş yükü izinin yukarıda sayılan özellikleri sağladığı varsayılmış ve bu iz çalışmamızda model oluşturmak için kullanılmıştır.

Bu çalışmamızda bulut bilişim için sanal makine-tabanlı sentetik iş yükü üretimi için aşağıdaki basamaklar takip edilmiştir:

**Verinin ön işleme:** Toplama süreci nedeni ile eksik bilgileri olan ya da iş yükünün kullanılacağı değerlendirme çalışması için anlamlı olmayan örneklerin izden çıkarılması.

**Verinin kümelmesi (clustering):** Seçilen ana iz parametrelerine göre benzer özellikteki iz örneklerinin kümelmesi. Bu şekilde ana iz parametrelerinin altında ayrı modeller üretilerek daha tanımlayıcı bir iş yükü modeli oluşturulabilir. Bu çalışmamızda kullandığımız k-ortalama kümeleme (k-means clustering) yöntemi [4]'te de kullanılmıştır. Bu yöntem,  $d$ -boyutlu örnekleri, küme içi örnek varyasyonu (sample variance) en az olacak şekilde  $k$  kümeye ayırır.

**Dağılım fonksiyonu uydurma:** Modellenerek yeniden üretilmek istenen sanal makine kullanım süresi, sanal makine başlangıç zaman aralıkları gibi sürekli parametreler için dağılım fonksiyonları uydurulur (distribution fitting), sanal makine boyutu gibi kategorik parametreler için ise popülasyon içerisinde gözlenme miktarları belirlenir. Dağılım uydurma yöntemi olarak maksimum olabilirlik kestirimi (maximum likelihood estimation) kullanılmıştır. Bu çalışmada bir grup aday dağılım arasından Anderson-Darling (AD) [9] hipotez testinde en yüksek  $p$  değerini veren dağılımlar veriye en iyi oturan dağılım olarak seçilmiştir. AD testleri ve benzeri uyum testleri büyük veri setleri için uygun olmadığı için rasgele seçilen veri alt kümelerinde uygulanmaktadır.

**İş yükü izi oluşturma:** Her oluşturulacak iz için kümeleme sonucunda ortaya çıkan gruplardan birisi grupların tüm veri setindeki sıklığına göre seçilir ve seçilen gruba uydurulan dağılımlara göre veri izi üretilir.

#### B. Azure Sanal Makine İzine Göre İş Yükü Modellemesi

Çalışmamızda [6]'da kullanılan ve [2]'de sunulan anonim hale getirilmiş Azure sanal makine (Virtual Machine-VM) izi kullanılmıştır. Bu iz, 2016 sonlarında bir Azure veri merkezi

üzerinde koşan tüm VM'lerin bilgilerinin 1 ay boyunca kaydedilmesiyle oluşturulmuştur. Hepsini bu çalışmada kullanılmayan bilgiler arasında VM'lerin geliş ve ayrılış zamanları, ayrılmış CPU çekirdek sayısı ve bellek büyüklüğü vardır. İzde yaklaşık 2 milyon VM kaydı bulunmaktadır. Kayıt  $i$ , ilgili VM'in başlatılma zamanı  $t_i^s$ , bitme zamanı  $t_i^f$  bilgilerini içermektedir. VM'in türünü (flavor) ayrılan bellek miktarı  $m_i$  (GB) ve işlemci çekirdek sayısı  $c_i$  gösterir. Bunların yanısıra bu çalışmada kullanmadığımız kullanıcı abonelik bilgileri, çekirdek kullanım oranı (CPU Utilization) bilgileri de bulunmaktadır.

**Verinin ön işleme** kapsamında iz verisinde elemeler ve varsayımlar yapılmıştır. Başlangıç tarihi iz kaydının başladığı tarih olan ve/veya bitiş günü iz kaydının son günü olan VM kayıtları, VM'lerin gerçek başlangıç ve bitiş zamanları kayıt aralığı dışında olabileceğinden dolayı işlenen verinin dışında bırakılmıştır. Bu tip kayıtlar, tüm kayıtların %14.2'sini oluşturmaktadır.

İzde bulunan kayıtların zaman çözünürlüğü 5 dakikadır. Örneğin (0, 300]. saniye arasında başlamış olabilecek bir VM, kayıta 300. saniyede başlamış görünmektedir. 5 dakikadan daha kısa kullanım süresi olan bir VM'in başlangıç ve bitiş zamanı zaman çözünürlüğünden dolayı kayıta aynı değerdedir. Kayıt çözünürlüğünün modelimize etkisini azaltmak başlangıç ve bitiş zamanları  $t_i^{start}$  ve  $t_i^{finish}$  olarak düzeltilmiştir.  $t_i^s < t_i^f$  durumunda  $t_i^{start}$ ,  $(t_i^s - 300; t_i^s)$  aralığından;  $t_i^{finish}$ ,  $(t_i^f - 300; t_i^f)$  aralığında düzgün dağılımla rastgele belirlenir.  $t_i^s = t_i^f$  durumunda ise (tüm kayıtların %2.84'ü)  $t_i^{start}$ ,  $(t_i^s - 300; t_i^s)$  aralığından;  $t_i^{finish}$ ,  $(t_i^{start}; t_i^s)$  aralığından düzgün dağılımla rastgele belirlenerek  $t_i^{start} < t_i^{finish}$  sağlanır.

**Verinin kümelmesi (clustering)** kapsamında Azure izindeki kayıtlardaki bilgiler kullanılarak her kayıt  $i$  için bellek  $m_i$  ve işlemci çekirdek sayısı  $c_i$  ile birlikte VM kullanım süresi  $t_i^{finish} - t_i^{start}$  olarak hesaplanmış ve veri seti bu 3 boyut üzerinden k-ortalama kümeleme (k-means clustering) yöntemi ile kümelmiştir. Küme sayısını gösteren  $k$  değeri [10]'da tanımlanan  $f(k)$  minimum olacak şekilde seçilmiştir. Bunun sebebi [10]'da yazarların  $f(k)$ 'in minimum olduğu  $k$  değeri için kümelerin daha sıkı olduğunu belirtmesidir. Tablo I'de  $f(k)$  değerleri görülebilir.

TABLE I: k-Ortalama Kümeleme Algoritması İçin  $k$  Seçim Analizi

$k$	1	2	3	4	5	6	7	8	9
$f(k)$	1.0	0.44	0.83	0.69	0.54	0.75	0.68	0.90	0.97

Buna uygun olarak  $k = 2$  seçilmiş, VM1 ve VM2 olarak iki sanal makine tipi belirlenmiştir. Bu iki tip için elde edilen değerler Tablo II'de gösterilmektedir.

VM1 tipi sanal makineler çekirdek sayısı ve bellek istemi açısından daha büyük değerlere sahip olup popülasyonun %14.4'lük bir kısmını oluşturmaktadır. VM1 ve VM2 grupları için değişim katsayılarının (Coefficient of Variation,  $cV$ ) küçük olması kümelerin kendi içlerinde bu parametreler bazında sıkı gruplanmış olduğunu göstermektedir.

TABLO II: Grup Merkezleri (Cluster Centers)

		Kullanım Süresi (s)	Çekirdek Sayısı	Bellek (GB)
VM1(14.44%)	$\mu$	33321	8	25.26
	cV	4.40	0.03	0.74
VM2(85.56%)	$\mu$	37149	1.67	2.90
	cV	4.61	0.59	0.61

TABLO III: Uydurulan Dağılımlar, Parametreleri ve Uyum İyiliği Test Sonuçları

VM1	Dağılım	VM Kullanım Süresi	VM Başlangıç zaman aralıkları
		Lognormal	Generalized Pareto
VM1	Parametreler	$\mu = 8.619$ $\sigma = 1.817$	$k = 0.471$ $\sigma = 5.233$ $\theta = 0$
	$p$	0.42	0.97
	Dağılım	Generalized Extreme Value	Generalized Pareto
VM2	Parametreler	$k = 1.519$ $\sigma = 2014.61$ $\mu = 1245.82$	$k = 0.274$ $\sigma = 1.186$ $\theta = 0$
	$p$	0.087	0.71

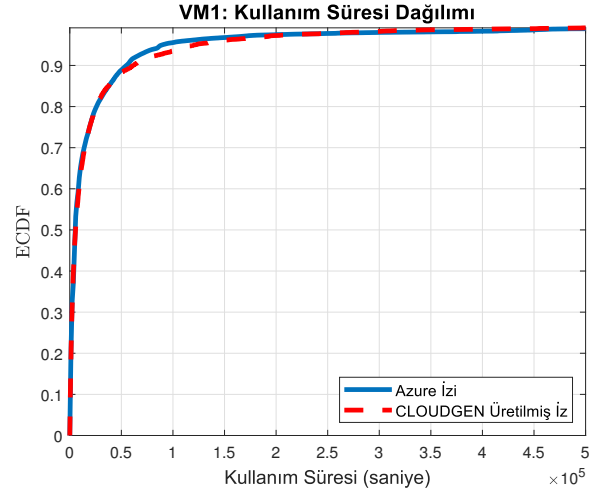
**Dağılım fonksiyonu uydurma:** Küme  $j$  ( $j = VM1$  veya  $j = VM2$ ) içindeki kayıt  $j, i$  için VM başlangıç zaman aralığı  $t_{j,i}^{start} - t_{j,i-1}^{start}$ , VM kullanım süresi  $t_{j,i}^{finish} - t_{j,i}^{start}$  olarak hesaplanmış ve bu sürekli değişkenler için dağılımlar uydurulmuştur. Dağılım uydurma için MATLAB'ta bulunan *fitdist* ve *adtest* fonksiyonları kullanılmıştır. Aday dağılımlar olarak [11]'de bulunan sürekli dağılımlar kullanılmıştır. Oturtulan dağılımlar ile iz verisinden rastgele çekilen 10 adet alt küme AD Testine sokulmuştur. Daha sonra sonuçlar Fisher Yöntemi [9] ile birleştirilmiştir. Kategorik değişkenler olan bellek miktarı ve işlemci çekirdek sayısı parametrelerinin tanımladığı VM türlerinin popülasyon içerisinde görülme sıklıkları hesaplanmıştır. Sonuçlar Tablo III ve IV'te görülebilir. Her parametre için  $p$  değeri 0.05'ten büyük bulunmuştur ve dağılımların uyumlu olduğunu ifade eden farksızlık hipotezi (null hypothesis) doğrulanmıştır.

### C. Modele Göre İş Yükü İzi Üretimi


CLOUDGEN modeli ile sağlanan bilgiler kullanılarak sentetik iş yükü izi üretmek mümkündür. Öncelikle yaratılacak VM izinin hangi kümeden (VM1/VM2) olacağı ve küme içinde hangi türden olacağı Tablo II ve Tablo III'e göre belirlenir. Daha sonra seçilen kümedeki uydurulmuş kullanım süresi dağılımı kullanılarak VM izi için kullanım süresi üretilir. VM başlatma zamanı kümedeki uydurulmuş başlangıç zaman aralığı dağılımına göre üretilen değer aynı kümedeki bir

TABLO IV: VM Türlerinin Gruplar İçerisinde Görülme Yüzdeleri

	VM türü	Görülme Yüzdesi
VM1	8 core, 14 GB RAM	73.12%
	8 core, 56 GB RAM	26.63%
	8 core, 16 GB RAM	0.016%
	8 core, 64 GB RAM	0.0026%
	4 core, 28 GB RAM	0.155%
	4 core, 32 GB RAM	0.0133%
	16 core, 112 GB RAM	0.055%
VM2	1 core, 1.75 GB RAM	55.748%
	1 core, 0.75 GB RAM	2.411%
	1 core, 2 GB RAM	0.033%
	2 core, 3.5 GB RAM	29.049%
	2 core, 14 GB RAM	0.019%
	2 core, 4 GB RAM	0.015%
	2 core, 16 GB RAM	0.009%
	4 core, 7 GB RAM	12.712%
	4 core, 8 GB RAM	0.004%



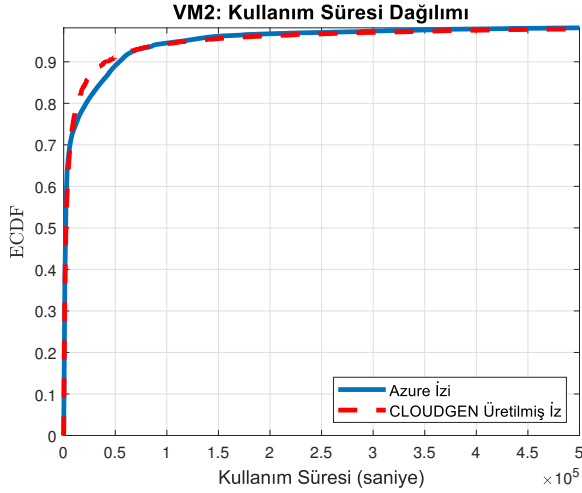
Şekil 1: Azure İzi ve CLOUDGEN tarafından üretilmiş izlerdeki 1. tip sanal makinelerin kullanım -süreleri empirik kümülatif dağılımları (Empirical Cumulative Distribution Function-ECDF).



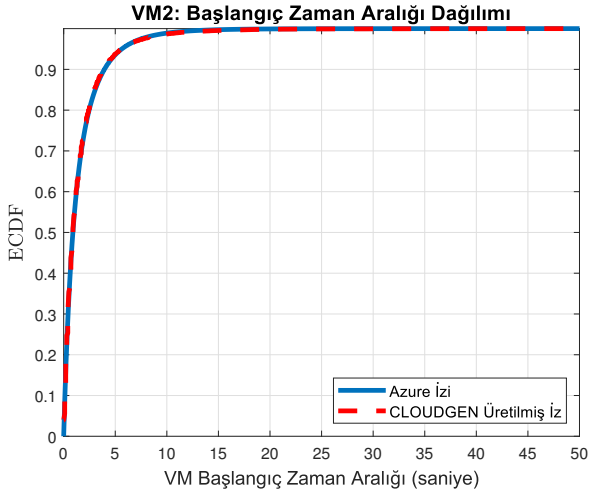
Şekil 2: Azure İzi ve CLOUDGEN tarafından üretilmiş izlerdeki 1. tip sanal makinelerin başlangıç zaman aralıkları empirik kümülatif dağılımları.

önceki sanal makine izi başlangıç zamanına eklenmesi ile oluşturulur.

CLOUDGEN iş akışını kullanarak bir iş yükü izi oluşturup, bu izi orijinal iş yükü ile grafiksel olarak karşılaştırılmıştır. Bu grafiklerde iş yükü analizinde kullanılan yöntemler üretilmiş iş yükü izi için de uygulanmış ve bulunan kümelerdeki sanal makine parametre dağılımlarının empirik kümülatif dağılım fonksiyonları (ECDF) orijinal izine ait parametrelerin dağılımları ile birlikte sunulmuştur. Şekil 1, 2, 3, 4'ten görülebileceği gibi CLOUDGEN ile üretilen sentetik iş yükü izleri her iki sanal makine tipi için de kullanım süreleri ve VM başlangıç zaman aralıklarına göre Azure izine büyük oranda benzerlik göstermektedir. Bu dağılımlara bakıldığında daha çok kaynak talep eden VM1 tipi sanal makinelerin daha düşük sıklıkla talep edildiği gözlemlenmiştir.



Şekil 3: Azure İzi ve CLOUDGEN tarafından üretilmiş izlerdeki 2. tip sanal makinelerin kullanım süreleri empirik kümülatif dağılımları.



Şekil 4: Azure İzi ve CLOUDGEN tarafından üretilmiş izlerdeki 1. tip sanal makinelerin başlangıç zaman aralıkları empirik kümülatif dağılımları.

#### IV. SONUÇ VE GELECEKTEKİ ÇALIŞMALAR

Bu bildiriye, Azure tarafından 2016'da paylaşılan iş yükü izi tanımlayıcı bir şekilde modellenmiş ve yeniden üretilebilir bir formatta sunulmuştur. IaaS/PaaS servisleri için uygun bir iş yükü modellemesi için k-ortalama kümelendirme yöntemi kullanılarak oluşturulan sanal makineler kümelere ayrılmıştır. Bu kümeler içerisinde kategorik özelliklerin popülasyon içerisinde görülme oranları belirlenmiş, süreklilik gösteren parametreler için ise dağılım uydurma metodu kullanılmıştır. Uydurulan dağılımlar uyum iyiliği hipotez testlerine tabi tutularak iz karakteristiklerinin gösterdikleri gözlemlenmiştir. Bu modeller kullanılarak sentetik izler oluşturulmuş ve Azure izleri ile benzer oldukları gösterilmiştir. Önerdiğimiz CLOUDGEN iş akışı bulut bilişim kaynak yönetimi çalışmalarında kullanılacak modelleri detaylı olarak sunmaktadır. Buna ek olarak modelleme yaklaşımı bulut bilişim iş yüklerinin daha detaylı

anlaşılmasına da imkan sağlamaktadır.

CLOUDGEN tarafından üretilen işyükleri, yeni bulut bilişim kaynak yönetimi yaklaşımlarının [12] testleri için kullanılacaktır. Sonraki çalışmalarda kümeleme yerine VM türlerinin kategorik yapısı göz önünde bulundurularak iş yükü modellemesi yapılabilir, Azure izinde bulunan işlemci kullanım miktarı bilgisi modellemeye dahil edilebilir ve CLOUDGEN iş akışının bilinen bulut bilişim simülasyon araçlarına entegrasyonu sağlanabilir.

#### TEŞEKKÜR

Bu çalışma, 117E667-117E668 nolu proje kapsamında TÜBİTAK tarafından desteklenmektedir. Yazarlar desteklerinden dolayı TÜBİTAK'a ve ASELSAN A.Ş.'ye teşekkür eder.

#### KAYNAKLAR

- [1] D. Magalhães, R. N. Calheiros, R. Buyya, and D. G. Gomes, "Workload modeling for resource usage analysis and simulation in cloud computing," *Computers & Electrical Engineering*, vol. 47, pp. 69–81, 2015.
- [2] "Azure/azurepublicdataset," accessed: 2018-06-30. [Online]. Available: <https://github.com/Azure/AzurePublicDataset>
- [3] A. Ganapathi, Y. Chen, A. Fox, R. Katz, and D. Patterson, "Statistics-driven workload modeling for the cloud," in *2010 IEEE 26th International Conference on Data Engineering Workshops (ICDEW 2010)*, March 2010, pp. 87–92.
- [4] I. S. Moreno, P. Garraghan, P. Townend, and J. Xu, "Analysis, modeling and simulation of workload patterns in a large-scale utility cloud," *IEEE Transactions on Cloud Computing*, vol. 2, no. 2, pp. 208–221, April 2014.
- [5] D. Magalhães, R. N. Calheiros, R. Buyya, and D. G. Gomes, "Workload modeling for resource usage analysis and simulation in cloud computing," *Computers & Electrical Engineering*, vol. 47, pp. 69–81, 2015.
- [6] E. Cortez, A. Bonde, A. Muzio, M. Russinovich, M. Fontoura, and R. Bianchini, "Resource central: Understanding and predicting workloads for improved resource management in large cloud platforms," in *Proceedings of the 26th Symposium on Operating Systems Principles*. ACM, 2017, pp. 153–167.
- [7] F. Nwanganga, N. V. Chawla, and G. Madey, "Statistical analysis and modeling of heterogeneous workloads on amazon's public cloud infrastructure," in *Proceedings of the 52nd Hawaii International Conference on System Sciences*, 2019.
- [8] D. G. Feitelson, "Workload modeling for performance evaluation," in *Performance Evaluation of Complex Systems: Techniques and Tools*, M. C. Calzarossa and S. Tucci, Eds. Berlin, Heidelberg: Springer Berlin Heidelberg, 2002, pp. 114–141.
- [9] "Nist/sematech e-handbook of statistical methods," accessed: 2018-12-21. [Online]. Available: <http://www.itl.nist.gov/div898/handbook/>
- [10] D. T. Pham, S. S. Dimov, and C. D. Nguyen, "Selection of k in k-means clustering," *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, vol. 219, no. 1, pp. 103–119, 2005.
- [11] "Mathworks documentation," accessed: 2019-01-10. [Online]. Available: [https://www.mathworks.com/help/stats/fitdist.html?s\\_tid=doc\\_ta](https://www.mathworks.com/help/stats/fitdist.html?s_tid=doc_ta)
- [12] A. Yazar, A. Erol, and E. G. Schmidt, "Accloud (accelerated cloud): A novel fpga-accelerated cloud architecture," in *2018 26th Signal Processing and Communications Applications Conference (SIU)*. IEEE, 2018, pp. 1–4.