(19) 대한민국특허청(KR)
(12) 등록특허공보(B1)

(45) 공고일자 2020년11월04일
(11) 등록번호 10-2174262
(24) 등록일자 2020년10월29일

(51) 국제특허분류(Int. Cl.)
H04W 72/12 (2009.01) *G06N 20/10* (2019.01)
H04L 12/867 (2013.01) *H04W 24/06* (2009.01)
(52) CPC특허분류
H04W 72/1205 (2013.01)
G06N 20/10 (2019.01)
(21) 출원번호 10-2019-0044648
(22) 출원일자 2019년04월17일
심사청구일자 2019년04월17일
(56) 선행기술조사문헌
Naoki Aihara et al., "Orthogonal Resource Allocation Using SVM for CSMA/CA", APSIPA (2018.11.12.)
Robert Margolies et al., "Exploiting Mobility in Proportional Fair Cellular Scheduling: Measurements and Algorithms", IEEE (2014.04.)
JP05265559 B

(73) 특허권자
인천대학교 산학협력단
인천광역시 연수구 아카데미로 119 (송도동)
(72) 발명자
김훈
인천광역시 연수구 송도문화로28번길 28, 106동 1203호(송도동, 송도글로벌캠퍼스푸르지오)
조홍평
인천광역시 서구 가남로 175-6, 2동 301호(가좌동, 상록수빌라)
(74) 대리인
특허법인충정

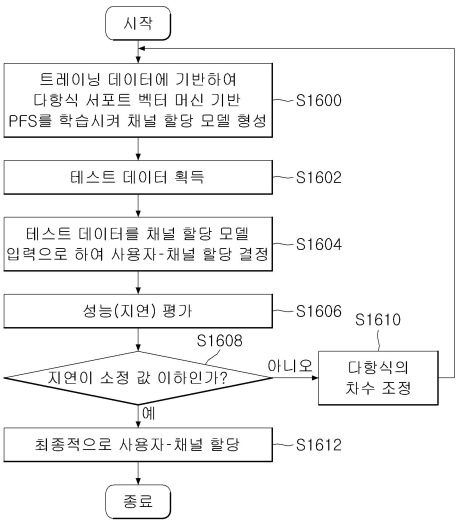
전체 청구항 수 : 총 6 항 심사관 : 나용수

(54) 발명의 명칭 **무선 통신 네트워크에서 기계 학습을 이용한 패킷 스케줄링 방법 및 장치**

(57) 요 약

본 발명의 일 실시예에 의한 무선 통신 네트워크에서 기계 학습을 이용한 패킷 스케줄링 방법은, (a) 채널 할당과 관련된 트레이닝 데이터에 기반하여 기계 학습 기반 비례 공정 스케줄링(PFS: Proportional Fair Scheduling)을 수행하여 이동국을 사용하는 사용자 를 채널에 할당하기 위한 채널 할당 모델을 형성하는 단계; (b) 채널 할당과 관련된 테스트 데이터를 획득하는 단계; 및 (c) 상기 테스트 데이터를 상기 채널 할당 모델의 입력으로 하여 사용자-채널 할당을 결정하는 단계를 포함하고, 상기 채널 할당과 관련된 트레이닝 데이터 및 테스트 데이터는, 채널 정보, 이전 타임 슬롯까지의 사용자의 평균 처리량, 및 이전 타임 슬롯의 선택된 사용자 중 적어도 하나를 포함한다.

대 표 도 - 도16



(52) CPC특허분류
H04L 47/629 (2013.01)
H04W 24/06 (2013.01)

이 발명을 지원한 국가연구개발사업
과제고유번호 1345281633
부처명 교육부
과제관리(전문)기관명 한국연구재단
연구사업명 개인기초연구(교육부)(R&D)
연구과제명 초신뢰저지연서비스를 위한 학습기반 포그 네트워크 캐싱 최적화 기술 연구
기 여 율 1/1
과제수행기관명 인천대학교 산학협력단
연구기간 2018.06.01 ~ 2019.02.28

명 세 서

청구범위

청구항 1

(a) 채널 할당과 관련된 트레이닝 데이터에 기반하여 기계 학습 기반 비례 공정 스케줄링(PFS: Proportional Fair Scheduling)을 수행하여 이동국을 사용하는 사용자를 채널에 할당하기 위한 채널 할당 모델을 형성하는 단계;

(b) 채널 할당과 관련된 테스트 데이터를 획득하는 단계; 및

(c) 상기 테스트 데이터를 상기 채널 할당 모델의 입력으로 하여 사용자-채널 할당을 결정하는 단계를 포함하고,

상기 채널 할당과 관련된 트레이닝 데이터는 상기 채널 할당 모델을 형성하기 위한 채널 정보, 상기 채널 할당 모델을 형성하기 위한 이전 타임 슬롯까지의 사용자의 평균 처리량, 및 상기 채널 할당 모델을 형성하기 위한 이전 타임 슬롯의 선택된 사용자 중 적어도 하나를 포함하고,

상기 채널 할당과 관련된 테스트 데이터는 상기 사용자-채널 할당을 결정하는데 사용되는 채널 정보, 상기 사용자-채널 할당을 결정하는데 사용되는 이전 타임 슬롯까지의 사용자의 평균 처리량, 및 상기 사용자-채널 할당을 결정하는데 사용되는 이전 타임 슬롯의 선택된 사용자 중 적어도 하나를 포함하는, 무선 통신 네트워크에서 기계 학습을 이용한 패킷 스케줄링 방법.

청구항 2

청구항 1에 있어서,

상기 기계 학습 기반 비례 공정 스케줄링은 다항식 서포트 벡터 머신 기반 비례 공정 스케줄링을 포함하는, 무선 통신 네트워크에서 기계 학습을 이용한 패킷 스케줄링 방법.

청구항 3

청구항 2에 있어서,

상기 단계 (c) 이후에,

(d) 사용자-채널 할당의 결과에 대한 성능 평가를 수행하는 단계;

(e) 상기 성능 평가 결과, 사용자-채널 할당에 소정값 이하의 지연이 발생하는 지를 판단하는 단계;

(f) 사용자-채널 할당에 소정값보다 큰 지연이 발생하는 경우, 상기 다항식 서포트 벡터 머신의 다항식의 차수를 조정하고, 상기 단계 (a)로 진행하는 단계; 및

(g) 사용자-채널 할당에 소정값 이하의 지연이 발생하는 경우, 상기 단계 (c)에서 결정된 사용자-채널 할당 결과에 기반하여 사용자를 채널에 할당하는 단계를 더 포함하는, 무선 통신 네트워크에서 기계 학습을 이용한 패킷 스케줄링 방법.

청구항 4

채널 할당과 관련된 트레이닝 데이터에 기반하여 기계 학습 기반 비례 공정 스케줄링(PFS: Proportional Fair Scheduling)을 수행하여 이동국을 사용하는 사용자를 채널에 할당하기 위한 채널 할당 모델을 형성하기 위한 기계 학습 기반 비례 공정 스케줄러; 및

채널 할당과 관련된 테스트 데이터를 획득하기 위한 테스트 데이터 획득부를 포함하고,

상기 기계 학습 기반 비례 공정 스케줄러는 상기 테스트 데이터를 상기 채널 할당 모델의 입력으로 하여 사용자-채널 할당을 결정하며,

상기 채널 할당과 관련된 트레이닝 데이터는 상기 채널 할당 모델을 형성하기 위한 채널 정보, 상기 채널 할당

모델을 형성하기 위한 이전 타임 슬롯까지의 사용자의 평균 처리량, 및 상기 채널 할당 모델을 형성하기 위한 이전 타임 슬롯의 선택된 사용자 중 적어도 하나를 포함하고,

상기 채널 할당과 관련된 테스트 데이터는 상기 사용자-채널 할당을 결정하는데 사용되는 채널 정보, 상기 사용자-채널 할당을 결정하는데 사용되는 이전 타임 슬롯까지의 사용자의 평균 처리량, 및 상기 사용자-채널 할당을 결정하는데 사용되는 이전 타임 슬롯의 선택된 사용자 중 적어도 하나를 포함하는, 무선 통신 네트워크에서 기계 학습을 이용한 패킷 스케줄링 장치.

청구항 5

청구항 4에 있어서,

상기 기계 학습 기반 비례 공정 스케줄러는 다항식 서포트 벡터 머신 기반 비례 공정 스케줄러를 포함하는, 무선 통신 네트워크에서 기계 학습을 이용한 패킷 스케줄링 장치.

청구항 6

청구항 5에 있어서,

사용자-채널 할당의 결과에 대한 성능 평가를 수행하기 위한 성능 평가부를 더 포함하고,

상기 성능 평가부는,

상기 성능 평가 결과, 사용자-채널 할당에 소정값 이하의 지연이 발생하는 지를 판단하는 동작;

사용자-채널 할당에 소정값보다 큰 지연이 발생하는 경우, 상기 다항식 서포트 벡터 머신의 다항식의 차수를 조정하는 동작; 및

사용자-채널 할당에 소정값 이하의 지연이 발생하는 경우, 상기 기계 학습 기반 비례 공정 스케줄러에 의해 결정된 사용자-채널 할당 결과를 최종 사용자-채널 할당 결과로서 출력하는, 무선 통신 네트워크에서 기계 학습을 이용한 패킷 스케줄링 장치.

발명의 설명

기 술 분 야

[0001] 본 발명은 무선 통신 네트워크에서 기계 학습을 이용한 패킷 스케줄링 방법 및 장치에 관한 것이다.

배 경 기 술

[0002] 무선 통신 네트워크에서 패킷 스케줄링의 목적은 전송 채널과 접속 사용자들 간의 효율적인 할당을 찾는 것이다. 패킷 스케줄링 문제에 대한 대부분의 솔루션은 주로 규정된 알고리즘 또는 반복 계산을 기반으로 한다. F. P. Kelly[4]에 의해 제안된 비례 공정 스케줄링(PFS: proportional fair scheduling)은 사용자 처리량의 대수 합을 최대화한다. 이것은 시스템 처리량과 공정성 사이에서 우수한 트레이드 오프를 제공하는 가장 실질적인 스케줄링 정책 중 하나로 간주된다. 단일 및 다중 캐리어 시스템을 위한 PFS가 제안되었고 무선 통신 네트워크 시스템 성능 평가에 널리 사용되었다.

[0003] 한편, 가까운 장래에 높은 컴퓨팅 파워가 통신 네트워크에 탑재될 것으로 기대됨에 따라 네트워크 리소스 할당에 있어서의 기계 학습(ML: Machine Learning) 기술의 필요성이 대두되었다. 비특허문헌 [9]에서 네트워크 구조에서 다중 계층으로 분산된 ML 모듈이 제안되었고 라우팅 문제에 대한 기계 학습 응용이 고려되었다[10]. 비특허문헌 [11]에서 기계 학습을 사용하여 패킷 교환형 광 네트워크(PSON: packet-switched optical network)의 각 모듈에서 플로우를 검출할 것을 제안한다. 그러나 특정 스케줄링 알고리즘에 대한 기계 학습 도입의 타당성 조사, 그 효과성 및 문제점과 같은 일부 문제는 아직 해결되지 않고 있다.

선행기술문헌

비특허문헌

[0004] (비특허문헌 0001) [1] R. Kwan, C. Leung, and J. Zhang, Multiuser scheduling on the downlink of an LTE cellular system, Research Letters in Communications, Vol. 2008, pp. 1-4, May, 2008.

(비특허문헌 0002) [2] M. Zulhasnine, C. Huang, and A. Srinivasan, Efficient resource allocation for device-to-device communication underlaying LTE network, 2010 IEEE 6th International Conference on Wireless and Mobile Computing, Networking and Communications, Niagara Falls, Ontario, October, 2010, pp. 368-375.

(비특허문헌 0003) [3] A. Pokhariyal, K. I. Pedersen, G. Monghal, I. Z. Kovacs, C. Rosa, T. E. Kolding, and P. E. Mogensen, 2007 IEEE 65th Vehicular Technology Conference-VTC2007-Spring, IEEE Vehicular Technology Conference, Dublin, Leinster, 2007, pp. 2761-2765.

(비특허문헌 0004) [4] F. P. Kelly, Charging and rate control for elastic traffic, European Transactions on Telecommunications, Vol. 8, pp. 33-37, January-February, 1997.

(비특허문헌 0005) [5] S. B. Lee, I. Pefkianakis, A. Meyerson, S. Xu, and S. Lu, Proportional Fair Frequency-Domain Packet Scheduling for 3GPP LTE Uplink, IEEE INFOCOM 2009, Rio de Janeiro, Brazil, April, 2009, pp. 2611-2615.

(비특허문헌 0006) [6] A. Jalali, R. Padovani, and R. Pankaj, Data Throughput of CDMA-HDR a High Efficiency-High Data Rate Personal Communication Wireless System, Proceeding of IEEE Vehicular Technology Conference-Spring, Tokyo, Japan, February, 2000, pp. 1854-1858.

(비특허문헌 0007) [7] H. Kim and Y. Han, A proportional fair scheduling for multicarrier transmission systems, IEEE Communications Letters, Vol. 9, No. 3, pp. 210-212, March, 2005.

(비특허문헌 0008) [8] S. Teerapittayanon, B. McDanel, and H. Kung, Distributed Deep Neural Networks over the Cloud the Edge and End Devices, https://arxiv.org/abs/1709.01921.

(비특허문헌 0009) [9] A. Valadarsky, M. Schapira, D. Shahaf, and A. Tamar. A Machine Learning Approach to Routing. https://arxiv.org/abs/1708.03074.

(비특허문헌 0010) [10] L. Wang, X. Wang, M. Tornatore, K. Kim, S. Kim, D. Kim, K. Han, and B. Mukherjee, Scheduling with Machine-Learning- Based Flow Detection for Packet-Switched Optical Data Center Networks, Journal of Optical Communications and Networking, Vol. 10, No. 4, pp. 365-375, April, 2018.

(비특허문헌 0011) [11] A. G뱅ron, Hands-On Machine Learning with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems, O'Reilly Media, 2017.

(비특허문헌 0012) [12] Y. Chang, C. Hsieh, K. Chang, M. Ringgaard, and C. Lin., Training and Testing Low-degree Polynomial Data Mappings via Linear SVM., http://jmlr.csail.mit.edu/papers/v11/chang10a.html.

발명의 내용

해결하려는 과제

[0005] 본 발명이 해결하고자 하는 과제는 적은 계산량으로 효율적으로 사용자를 채널에 할당할 수 있는 무선 통신 네트워크에서 기계 학습을 이용한 패킷 스케줄링 방법을 제공하는 것이다.

[0006] 본 발명이 해결하고자 하는 다른 과제는 적은 계산량으로 효율적으로 사용자를 채널에 할당할 수 있는 무선 통신 네트워크에서 기계 학습을 이용한 패킷 스케줄링 장치를 제공하는 것이다.

과제의 해결 수단

[0007] 상기 과제를 해결하기 위한 본 발명의 일 실시예에 의한 무선 통신 네트워크에서 기계 학습을 이용한 패킷 스케줄링 방법은,

[0008] (a) 채널 할당과 관련된 트레이닝 데이터에 기반하여 기계 학습 기반 비례 공정 스케줄링(PFS: Proportional Fair Scheduling)을 수행하여 이동국을 사용하는 사용자를 채널에 할당하기 위한 채널 할당 모델을 형성하는 단

계;

[0009] (b) 채널 할당과 관련된 테스트 데이터를 획득하는 단계; 및

[0010] (c) 상기 테스트 데이터를 상기 채널 할당 모델의 입력으로 하여 사용자-채널 할당을 결정하는 단계를 포함하고,

상기 채널 할당과 관련된 트레이닝 데이터는 상기 채널 할당 모델을 형성하기 위한 채널 정보, 상기 채널 할당 모델을 형성하기 위한 이전 타임 슬롯까지의 사용자의 평균 처리량, 및 상기 채널 할당 모델을 형성하기 위한 이전 타임 슬롯의 선택된 사용자 중 적어도 하나를 포함하고,

[0011] 상기 채널 할당과 관련된 테스트 데이터는 상기 사용자-채널 할당을 결정하는데 사용되는 채널 정보, 상기 사용자-채널 할당을 결정하는데 사용되는 이전 타임 슬롯까지의 사용자의 평균 처리량, 및 상기 사용자-채널 할당을 결정하는데 사용되는 이전 타임 슬롯의 선택된 사용자 중 적어도 하나를 포함한다.

[0012] 본 발명의 일 실시예에 의한 무선 통신 네트워크에서 기계 학습을 이용한 패킷 스케줄링 방법에 있어서, 상기 기계 학습 기반 비례 공정 스케줄링은 다항식 서포트 벡터 머신 기반 비례 공정 스케줄링을 포함할 수 있다.

[0013] 또한, 본 발명의 일 실시예에 의한 무선 통신 네트워크에서 기계 학습을 이용한 패킷 스케줄링 방법은, 상기 단계 (c) 이후에,

[0014] (d) 사용자-채널 할당의 결과에 대한 성능 평가를 수행하는 단계;

[0015] (e) 상기 성능 평가 결과, 사용자-채널 할당에 소정값 이하의 지연이 발생하는 지를 판단하는 단계;

[0016] (f) 사용자-채널 할당에 소정값보다 큰 지연이 발생하는 경우, 상기 다항식 서포트 벡터 머신의 다항식의 차수를 조정하고, 상기 단계 (a)로 진행하는 단계; 및

[0017] (g) 사용자-채널 할당에 소정값 이하의 지연이 발생하는 경우, 상기 단계 (c)에서 결정된 사용자-채널 할당 결과에 기반하여 사용자를 채널에 할당하는 단계를 더 포함할 수 있다.

[0018] 상기 다른 과제를 해결하기 위한 본 발명의 일 실시예에 의한 무선 통신 네트워크에서 기계 학습을 이용한 패킷 스케줄링 장치는,

[0019] 채널 할당과 관련된 트레이닝 데이터에 기반하여 기계 학습 기반 비례 공정 스케줄링(PFS: Proportional Fair Scheduling)을 수행하여 이동국을 사용하는 사용자를 채널에 할당하기 위한 채널 할당 모델을 형성하기 위한 기계 학습 기반 비례 공정 스케줄러; 및

[0020] 채널 할당과 관련된 테스트 데이터를 획득하기 위한 테스트 데이터 획득부를 포함하고,

[0021] 상기 기계 학습 기반 비례 공정 스케줄러는 상기 테스트 데이터를 상기 채널 할당 모델의 입력으로 하여 사용자-채널 할당을 결정하며,

상기 채널 할당과 관련된 트레이닝 데이터는 상기 채널 할당 모델을 형성하기 위한 채널 정보, 상기 채널 할당 모델을 형성하기 위한 이전 타임 슬롯까지의 사용자의 평균 처리량, 및 상기 채널 할당 모델을 형성하기 위한 이전 타임 슬롯의 선택된 사용자 중 적어도 하나를 포함하고,

[0022] 상기 채널 할당과 관련된 테스트 데이터는 상기 사용자-채널 할당을 결정하는데 사용되는 채널 정보, 상기 사용자-채널 할당을 결정하는데 사용되는 이전 타임 슬롯까지의 사용자의 평균 처리량, 및 상기 사용자-채널 할당을 결정하는데 사용되는 이전 타임 슬롯의 선택된 사용자 중 적어도 하나를 포함한다.

[0023] 본 발명의 일 실시예에 의한 무선 통신 네트워크에서 기계 학습을 이용한 패킷 스케줄링 장치에 있어서, 상기 기계 학습 기반 비례 공정 스케줄러는 다항식 서포트 벡터 머신 기반 비례 공정 스케줄러를 포함할 수 있다.

[0024] 또한, 본 발명의 일 실시예에 의한 무선 통신 네트워크에서 기계 학습을 이용한 패킷 스케줄링 장치는, 사용자-채널 할당의 결과에 대한 성능 평가를 수행하기 위한 성능 평가부를 더 포함하고,

[0025] 상기 성능 평가부는,

[0026] 상기 성능 평가 결과, 사용자-채널 할당에 소정값 이하의 지연이 발생하는 지를 판단하는 동작;

[0027] 사용자-채널 할당에 소정값보다 큰 지연이 발생하는 경우, 상기 다항식 서포트 벡터 머신의 다항식의 차수를 조정하는 동작; 및

[0028] 사용자-채널 할당에 소정값 이하의 지연이 발생하는 경우, 상기 기계 학습 기반 비례 공정 스케줄러에 의해 결정된 사용자-채널 할당 결과를 최종 사용자-채널 할당 결과로서 출력할 수 있다.

발명의 효과

[0029] 본 발명의 일 실시예에 의한 무선 통신 네트워크에서 기계 학습을 이용한 패킷 스케줄링 방법 및 장치에 의하면 적은 계산량으로 효율적으로 사용자를 채널에 할당할 수 있다.

도면의 간단한 설명

[0030] 도 1은 시스템 모델 및 비례 공정 스케줄링(PFS)을 도시한 도면.

도 2는 사용자 1에 대한 사용자 2의 비례 공정(PF) 메트릭 비율에 대한 선형 SVM 기반 PFS의 라벨 대 사용자 선택을 위한 예측을 도시한 도면.

도 3은 사용자 1에 대한 사용자 2의 비례 공정(PF) 메트릭의 비율에 대한 다항식 SVM 기반 PFS의 라벨 대 사용자 선택을 위한 예측을 도시한 도면.

도 4는 ML의 선형 SVM 모델을 사용하는 증가하는 SIR에 따른 사용자 선택률을 도시한 도면.

도 5는 ML의 다항식 SVM 모델을 사용하는 증가하는 SIR에 따른 사용자 선택률을 도시한 도면.

도 6은 ML의 선형 SVM 모델을 사용하는 상이한 SIR 값에 대한 두 사용자들 간의 처리량 비율을 도시한 도면.

도 7은 ML의 다항식 SVM 모델을 사용하는 상이한 SIR 값에 대한 두 사용자들 간의 처리량 비율을 도시한 도면.

도 8은 T=10에 대한 메트릭 기반 기법과 비교된 선형 SVM ML 기반 기법의 정확도를 도시한 도면.

도 9는 T=10에 대한 메트릭 기반 기법과 비교된 다항식 SVM ML 기반 기법의 정확도를 도시한 도면.

도 10은 T=20에 대한 메트릭 기반 기법과 비교된 선형 SVM ML 기반 기법의 정확도를 도시한 도면.

도 11은 T=20에 대한 메트릭 기반 기법과 비교된 다항식 SVM ML 기반 기법의 정확도를 도시한 도면.

도 12는 상이한 수의 트레이닝 샘플들에 대한 선형 SVM 기반 ML의 정확도를 도시한 도면.

도 13은 상이한 수의 트레이닝 샘플들에 대한 다항식 SVM 기반 ML의 정확도를 도시한 도면.

도 14는 사용된 다항식 차수에 관한 ML의 정확도를 도시한 도면.

도 15는 본 발명의 일 실시예에 의한 무선 통신 네트워크에서 기계 학습을 이용한 패킷 스케줄링 장치의 블록도.

도 16은 본 발명의 일 실시예에 의한 무선 통신 네트워크에서 기계 학습을 이용한 패킷 스케줄링 방법의 흐름도.

발명을 실시하기 위한 구체적인 내용

[0031] 본 발명의 목적, 특정한 장점들 및 신규한 특징들은 첨부된 도면들과 연관되어지는 이하의 상세한 설명과 바람직한 실시예들로부터 더욱 명백해질 것이다.

[0032] 이에 앞서 본 명세서 및 청구범위에 사용된 용어나 단어는 통상적이고 사전적인 의미로 해석되어서는 아니되며, 발명자가 그 자신의 발명을 가장 최선의 방법으로 설명하기 위해 용어의 개념을 적절하게 정의할 수 있는 원칙에 입각하여 본 발명의 기술적 사상에 부합되는 의미와 개념으로 해석되어야 한다.

[0033] 본 명세서에서 각 도면의 구성요소들에 참조번호를 부가함에 있어서, 동일한 구성 요소들에 한해서는 비록 다른 도면상에 표시되더라도 가능한 한 동일한 번호를 가지도록 하고 있음에 유의하여야 한다.

[0034] 또한, "제1", "제2", "일면", "타면" 등의 용어는, 하나의 구성요소를 다른 구성요소로부터 구별하기 위해 사용되는 것으로, 구성요소가 상기 용어들에 의해 제한되는 것은 아니다.

[0035] 이하, 본 발명을 설명함에 있어, 본 발명의 요지를 불필요하게 흐릴 수 있는 관련된 공지 기술에 대한 상세한 설명은 생략한다.

[0036] 이하, 첨부된 도면을 참조하여 본 발명의 바람직한 실시형태를 상세히 설명하기로 한다.

[0037] 본 발명에서는 무선 통신 네트워크에서 서포트 벡터 머신(SVM: Support Vector Machine) 모델 기반 패킷 스케줄링을 다룬다. 선형 SVM과 다항식 SVM 모델 기반 비례 공정 스케줄링(SVM-PFS)이 제안된다. 또한 평균 윈도우, 신호 대 간섭 비(SIR) 및 다항식의 차수와 같은 다양한 시스템 및 기계 학습 매개 변수에 대한 성능이 분석된다. 컴퓨터 시뮬레이션을 통해 사용자 선택 공정성 및 사용자 처리량과 같은 PFS의 성능 측정이 계산되어 SVM 모델 기반 PFS의 성능이 대부분의 경우 기존 메트릭 기반 PFS 성능에 근접함을 증명하고 시뮬레이션 결과는 다항식 SVM-PFS가 선형 SVM-PFS보다 우월하다는 것을 보여준다. 또한 SVM-PFS는 보다 높은 SIR 또는 더 큰 평균 윈도우에서 보다 잘 수행됨을 보여준다.

[0038] 또한, 본 발명에서는 컴퓨터 시뮬레이션을 기반으로 PFS 및 PFS를 능가하는 정확도를 달성하기 위하여 스케줄러를 트레이닝시키는 ML 기법이 제안된다. ML 알고리즘 중에는 SVM 분류 규칙이 적용되며 통신 링크의 다양한 평균 전력, 평균 윈도우 크기, 타임 슬롯 범위 및 사용된 다항식의 차수에 대한 정확도가 분석된다. 시뮬레이션으로부터, 높은 차수의 SVM, 높은 SIR 및 큰 평균 윈도우 하에서 ML 방식의 더 좋은 품질이 달성된다.

[0040] 시스템 모델 및 PFS(Proportional Fair Scheduling)

[0041] 시스템 모델

[0042] 도 1의 개략도는 메트릭 기반 및 ML 기반 접근 방식으로 수행되는 PFS를 보여준다. 네트워크 측으로부터 데이터를 수신하기 위해 사용자와 무선 액세스 포인트 사이의 통신 채널이 사용되는 다운 링크 패킷 스케줄링을 위한 시스템이 고려된다. 채널 정보는 완벽하게 수집된 것으로 가정하고 스케줄러는 각 사용자의 평균 처리량을 계산한다. 이러한 정보를 기반으로 스케줄러는 사용자를 채널에 할당한다.

[0044] 비례 공정 스케줄링 (PFS: Proportional Fair Scheduling)

[0045] 스케줄링은 다음 전송 시 데이터를 보낼 사용자를 선택하는 자원 할당 체계이다. 비례 공정성의 기준은 스케줄링의 라운드 로빈 및 최대 캐리어-투-간섭(CIR) 방법과 달리 시스템 처리량과 공정성 간에 우수한 트레이드 오프(절충)을 달성하기 때문에 무선 통신 네트워크에서 고려되었다. 이 방식에서, 사용자는 각각의 타임 슬롯에 액세스하는 동안 그들이 나타내는 성능에 기초하여 선택된다. 예를 들어, 현재 스케줄링 에포크에 대한 사용자는 현재 타임 슬롯의 채널 용량뿐만 아니라 이전 타임 슬롯에서 보여준 성능에 의해 결정된다.

[0046] 비례 공정 스케줄링(PFS: proportional fair scheduling)은 사용자 유틸리티가 사용자의 평균 처리량으로 정의될 때 아래와 같이 나타낼 수 있는 로그 사용자 유틸리티의 합을 최대화해야 한다는 것이 알려져 있다.

수학식 1

[0047] $$PFS = argmax_S \sum_i \log R_i^{(S)}$$

[0048] $R_i^{(S)}$ 는 스케줄러 s에 의해 예측되는 사용자 i의 평균 처리량으로서 하기와 같이 계산될 수 있다.

수학식 2

[0049] $$R_i^{(S)} = \frac{(T-1)\,R_i' + r_i^{(s)}}{T}$$

[0050] 여기서, T는 평균화 윈도우이고, R_i' 는 이전 타임 슬롯에서의 평균 처리량이며, $r_i^{(s)}$ 는 스케줄러 s가 바로 그 사용자를 할당하는 경우 현재 타임 슬롯에서의 사용자 i에 대한 순시 채널 용량이다. 순시 채널 용량 $r_i^{(s)}$

의 값은 각각의 타임 슬롯에서 스케줄러 s에 의해 할당되지 않은 사용자 i에 대해 0이 된다.

[0052] PFS 기법

[0053] 많은 스케줄링 기법들 중에서, PFS 스케줄링의 두 가지 방법, 즉 메트릭(metrice) 기반 스케줄링과 기계학습(ML) 기반 스케줄링에 대해서만 논의될 것이다. 메트릭 기반 스케줄러는 스케줄링 메트릭 계산을 기반으로 사용자-채널 매핑을 결정한다. 반면 ML 기반 스케줄러는 특징들을 사용하고 메트릭 계산없이 사용자-채널 매핑을 위한 출력을 생성한다.

[0055] 메트릭 기반 PFS

[0056] 메트릭 기반 PFS에서 메트릭 계산은 사용자-채널 매핑을 결정하기 위해 수행된다. 도 1에서 s는 사용자를 채널에 동일하게 매핑하고 사용자를 통신 채널에 할당하는 고유한 스케줄링 정책을 의미한다. 처리량과 공정성 간에 우수한 트레이드 오프를 유지하는 PFS가 최상의 스케줄링 정책이라고 가정한다. 단일 캐리어 무선 통신 시스템의 경우, 스케줄러는 사용자 인덱스에 의해 식별될 수 있으며, 이는 아래 주어진 수학식 3에서와 같이 사용자별 메트릭을 비교함으로써 간단하게 구현된다.

수학식 3

[0057]
$$PFS = argmax_i \frac{r_i^{(i)}}{R_i'}$$

[0058] 단일 캐리어 시스템에 대한 상기 PFS 수학식은 다음 타임 슬롯에 대한 사용자의 선택이 이전 타임 슬롯에서 나타난 성능에 의존한다는 것을 보여준다. 이는 스케줄링의 비-편향적인 체계이다. 그것은 이전 타임 슬롯에서 선택되지 않은 사용자를 선택하려고 시도한다. 예시를 위해, N 타임 슬롯에서, 모든 사용자가 N 타임 슬롯에서 동일한 처리량 ($r^{(i)}$)을 나타낸다고 가정하면, PFS는 N-1 타임 슬롯에서 다른 사용자보다 평균 처리량(R_i)이 비교적 적은 사용자를 선택하려고 시도한다

[0060] ML 기반 PFS

[0061] ML 기반 PFS에서 서포트 벡터 머신(SVM: support vector machine) 모델은 PFS를 다루는 동안 ML 접근법의 성능을 정량화하기 위해 선택된다. SVM은 데이터 분류에 널리 사용된다. SVM은 종종 데이터를 고차원 공간에 매핑한 다음 커널 기술을 사용한다. 두 가지 범주 중 하나 또는 다른 범주에 속하는 것으로 표시된 일련의 트레이닝 샘플들에서 SVM 트레이닝 알고리즘은 한 범주 또는 다른 범주에 새로운 샘플들을 할당하는 모델을 형성한다.

[0062] SVM 모델은 샘플들을 공간의 점으로 표현한 것으로, 개별 범주의 샘플들이 최대한 넓은 명확한 갭에 의해 나누어지는 방식으로 매핑된다. 그 다음 새로운 샘플들은 동일한 공간에 매핑되고 어떤 범주에 속하도록 예측되는데, 상기 범주는 상기 샘플들이 갭의 어느 쪽에 속하는 지에 기반한다. 이러한 종류의 SVM 분류를 라지 마진(large margin) 분류 또는 하드 마진(hard margin) 분류라고 한다. 하드 마진 분류에는 두 가지 주요 쟁점이 있다. 하드 마진 분류와 관련된 첫 번째 문제는 데이터가 선형으로 분리 가능한 경우에만 작동하고 두 번째 문제는 이상치에 상당히 민감하다는 것이다.

[0063] 하드 마진 분류와 관련된 문제를 완화하려면 소프트 마진 분류와 같이 보다 유연한 SVM 모델을 사용하는 것이 좋다. 소프트 마진 분류의 목표는 넓은 스트리트(street) 폭과 작은 마진 위반 사이의 균형을 잘 맞추는 것이다. Scikit-Learn의 SVM 클래스에서 C 하이퍼 매개 변수의 값을 변경함으로써 균형을 제어할 수 있다. C 값이 작을수록 스트리트가 넓어지지만 마진 위반이 많아지고, C 값이 클수록 마진 위반이 줄어들지만 마진은 줄어든다. C의 값은 스트리트의 폭과 마진 위반 사이에 좋은 절충을 제공하는 방식으로 선택되어야 한다.

[0065] 선형 SVM

[0066] 선형 SVM은 ML 알고리즘의 한 유형이다. 그것은 선형 접근 방식으로 데이터를 분류한다. 그것은 선형으로 분류할 수 있는 데이터, 즉 적은 수의 특징을 갖는 데이터에 완벽하게 작동한다. 선형 SVM은 최대 간격을 유지하는 방식으로 두 클래스 간을 분리하는 초평면을 찾으려고 한다. 초평면은 다음 수학식을 만족하는 d 차원의 x점들의 집합이다.

수학식 4

[0067] $$w^T + b = 0$$

수학식 5

[0068] $$h(x) = w^T + b$$

[0069] w는 d 차원을 갖는 가중치 벡터이고, h(x)는 초평면 함수이며, b는 바이어스(bias)를 나타내는 스칼라이다. 처음에 w와 b의 값은 알려지지 않는다. 분리하는 초평면 h(x)가 가능한 한 정확하게 두 개의 다른 데이터 클래스들을 분리할 수 있는 방식으로 w와 b의 값을 찾아야 한다.

[0070] 선형 SVM 분류기가 효율적이고 많은 경우에 놀랍도록 잘 작동하지만 많은 데이터 세트가 선형적으로 분리될 수는 없다. 이러한 종류의 시나리오에서, 비선형 SVM 알고리즘, 즉 다항식 SVM을 사용하는 것이 바람직하다.

[0072] 다항식 SVM

[0073] 다항식 SVM은 데이터를 선형적으로 분리할 수 없는 경우에 사용된다. 데이터를 상위 평면에 매핑하고 데이터를 분리하는 초평면을 만든다. 다수의 특징이 존재할 때, 다항식 SVM은 선형 SVM 방법과는 달리 특징들 간의 관계를 찾을 수 있다. 이러한 종류의 ML 알고리즘은 데이터에 많은 수의 특징들이 있는 경우에 사용된다. 예를 들어, x와 y의 두 가지 특징이 있고 차수가 3인 다항식 특징이 있는 경우, x^2, x^3, y^2 및 y^3의 특징들뿐만 아니라 특징들의 조합인 xy, x^2y, 및 xy^2가 추가될 것이다. 차수 d를 갖는 다항식 특징은 n개의 특징들을 포함하는 배열을 $\frac{(n+d)!}{n!d!}$ 개의 특징들을 포함하는 배열로 변환하는데, n!은 n의 계승이며, $1 \times 2 \times 3 \times \ldots n$이다. 특징들의 수의 조합 폭발을 염두에 두어야한다.

[0074] 본 발명의 일 실시예에서, 데이터가 2개 이상의 특징들에 의존하는 경우, 데이터를 분류하는 다항식 SVM 접근법이 데이터를 분류하는 선형 SVM 접근법보다 낫다는 것이 검증될 것이다.

[0076] 성능 평가

[0077] 시뮬레이션 매개 변수

[0078] 메트릭 기반 PFS 솔루션과 ML 기반 PFS의 성능을 비교하기 위해 일부 시스템 시나리오가 가정된다. ML 기반 PFS에서, 더 나은 결과를 찾기 위하여 선형 SVM 및 다항식 SVM 방법이 고려된다. 시뮬레이션에서 단일 전송 채널이 고려된다. 단일 채널은 2명의 사용자들에 의해 공유되며, 사용자 신호 대 간섭 비(SIR: signal to interference)의 통계는 레일리 페이딩(Rayleigh fading)과는 무관하다고 가정한다. 채널 용량은 Shannon의 정리, 즉 $\log_2(1+SIR)$을 사용하여 계산된다.

[0079] 본 발명의 일 실시예에서, ML에 사용된 분류 모델은 SVM이다. ML 특징들은 채널 용량, 평균 처리량을 포함하며, ML 라벨은 각 스케줄링 타임 슬롯에서 스케줄링된 사용자이다. ML 알고리즘의 정확성을 평가하기 위해 ML 기반 스케줄링 기법의 출력을 메트릭 기반 PFS와 비교한다.

[0080] 시뮬레이션을 위해 취해진 타임 슬롯은 다양한 채널 평균 전력에 대해 10,000이다. ML에 대한 트레이닝 및 테스트 데이터 세트는 타임 슬롯의 전후 절반으로 분할된다. 시뮬레이션에서, 트레이닝 데이터 세트에 대해, 1-5000 타임 슬롯이 취해진 반면, 테스트 데이터 세트에 대해서는, 5001-10000 타임 슬롯이 취해진다. 아래 표 1은 시뮬레이션 매개 변수와 고려되는 값들을 요약한 것이다.

표 1

[0081]

Parameters	Value
Number of users	2
Number of channel	1
Channel variation	Rayleigh
Channel capacity	$log_2(1+SIR)$
Average window timeslots (T)	10,20
ML model	SVM (linear, polynomial)
Number of timeslots	10,000
Test data sets	1-5000
Training data sets	5001-10000

[0083] 시뮬레이션 결과

[0084] PFS 특징

[0085] 비례 공정 메트릭, 사용자 선택률 및 사용자 처리량 공정성의 출력 결과가 선형 및 다항식 SVM-PFS에 대해 표시된다.

[0086] 도 2는 사용자 1에 대한 사용자 2의 비례 공정(PF) 메트릭 비율에 대한 선형 SVM 기반 PFS의 라벨 대 사용자 선택을 위한 예측을 도시한 것이다. y축에서 '0'은 사용자 1 선택을 의미하고 '1'은 사용자 2 선택을 의미한다.

[0087] 메트릭 기반 PFS는 사용자 1에 대한 사용자 2의 PF 메트릭의 비율이 1보다 클 경우 사용자 2를 선택한다. 선형 SVM 기반 PFS의 경우 1보다 큰 비율에 대해 사용자 2가 선택되지 않은 지점이 있고, 유사하게 1보다 작은 비율에 대해 사용자 1이 선택되지 않는 몇몇 점들이 존재한다.

[0088] 도 3은 사용자 1에 대한 사용자 2의 비례 공정(PF) 메트릭의 비율에 대한 다항식 SVM 기반 PFS의 라벨 대 사용자 선택을 위한 예측을 보여준다. 다항식 SVM 기반 PFS 방법에서, 1보다 큰 비율에 대해 사용자 2가 선택되지 않는 단지 소수의 지점 그리고 1보다 작은 비율에 대해 사용자 1이 선택되지 않는 단지 소수의 지점만이 존재함을 확인할 수 있다.

[0089] 도 2와 도 3을 비교하면 다항식 SVM 기반 PFS 방법이 선형 SVM 기반 PFS 방법보다 더 정확하게 사용자를 선택한다는 것을 알 수 있다.

[0090] 도 4와 도 5는 각각 선형 SVM과 다항식 SVM을 사용하는 PFS 방식의 사용자 선택률을 보여준다. 각각의 결과는 PFS 방식을 사용하는 상이한 사용자들 사이의 사용자 선택률이 평균적인 SIR의 값을 변경하더라도, 거의 0.5의 마진 라인과 유사하다는 것을 보여준다. 이 결과는 또한 메트릭 기반 PFS 기법뿐만 아니라 SVM-PFS 기법도 공정성 측면에서 유사한 출력을 표시함을 보여준다.

[0091] 도 6의 그래프는 ML의 선형 SVM 모델을 사용하는 여러 사용자들 간의 처리량 비율을 보여준다. 마찬가지로, 도 7의 그래프는 ML의 다항식 SVM 모델을 사용하는 사용자들 간의 처리량 비율을 보여준다.

[0092] 도 6과 도 7의 그래프는 사용된 ML 모델에 관계없이 PFS 기법의 서로 다른 사용자들 간의 처리량 비율이 SIR의 상이한 값에 따라 거의 비슷하다는 것을 보여준다.

[0094] 평균 타임 윈도우

[0095] SVM-PFS의 출력은 평균 타임 윈도우 T의 두 가지 다른 값에 대해 여기에 표시된다.

[0096] 도 8은 평균 타임 T=10에 대한 메트릭 기반 기법과 비교된 선형 SVM ML 기반 기법의 정확도를 보여준다. ML 정확도는 SIR의 다른 값에 대해 표시된다. 제안된 ML 기반 PFS 스케줄링의 성능은 대부분의 경우 기존 PFS의 성능에 거의 접근한다. 채널 평균 전력이 높을수록 정확도가 향상된다. 이는 채널 용량이 클수록 ML 알고리즘에 보다 안정적인 데이터 입력을 제공하여 오류가 더 적어지기 때문이다.

[0097] 도 9는 T=10에 대한 메트릭 기반 기법과 비교된 다항식 SVM ML 기반 기법의 정확도를 보여준다. 다항식 SVM ML 기반 기법에 의해 PFS 관점에서 보다 정확한 스케줄링이 달성되는 것이 확인된다. 이것은 특징들 내의 다항식 구성 요소가 다항식 SVM ML 기반 기법에 반영될 수 있어 오류가 더 적어지기 때문이다.

[0098] 마찬가지로, 도 10은 T=20에 대한 메트릭 기반 기법과 비교된 선형 SVM ML 기반 기법의 정확도를 보여준다. 도 8과 도 10을 비교하면 T의 값이 높으면 출력이 좋다고 말할 수 있다.

[0099] 마찬가지로, 도 11은 T=20에 대한 메트릭 기반 기법과 비교된 다항식 SVM ML 기반 기법의 정확도를 보여준다. 도 9와 도 11을 비교해 보면 도 11의 시뮬레이션 출력이 도 10보다 우수하다고 말할 수 있다.

[0101] 트레이닝 샘플들의 수

[0102] 다양한 값의 트레이닝 샘플에 대한 SVM-PFS의 결과가 여기에 표시된다.

[0103] 도 12는 상이한 수, 즉 각각 10, 100, 1000 및 10000개의 트레이닝 샘플들에 대한 선형 SVM 기반 ML의 정확도를 보여준다. ML의 정확도는 트레이닝 샘플이 10 배 증가할 때 증가 추세에 있고 특정 수의 트레이닝 샘플 이후에 거의 포화 상태에 있게 된다.

[0104] 마찬가지로, 도 13은 상이한 수의 트레이닝 샘플들에 대한 다항식 SVM 기반 ML의 정확도를 보여준다. 도 12와 도 13의 결과를 비교해 보면 다항식 SVM-PFS는 사용된 트레이닝 샘플들의 수와 관계없이 선형 SVM-PFS보다 더 정확한 결과를 제공한다는 결론을 이끌어 낼 수 있다.

[0106] 사용된 다항식의 차수

[0107] SVM-PFS의 시뮬레이션된 결과는 상이한 다항식 차수에 대해 여기에 표시된다.

[0108] 도 14는 다항식 차수를 늘리면 다항식 SVM의 정확도가 증가하는 경향을 보여준다는 것을 알 수 있다. 다항식 차수가 4인 경우, ML 정확도는 다항식 차수 5에서 아래로 떨어지지만, 다항식 차수가 6일 때 약간 개선된다. ML 알고리즘의 정확도에 대한 이러한 비정상적인 동작은 다항식의 차수가 증가함에 따라 복잡도가 증가하기 때문이다. 낮은 다항식 차수에 대한 낮은 정확도는 과소적합(underfitting)으로 인한 반면, 높은 다항식 차수에 대한 낮은 정확도는 과대적합(overfitting) 때문이다. 여기서 과대적합은 모델이 트레이닝 데이터에 대해 제대로 수행하지만 교차 유효성 검사 측정 항목으로 인해 불량 예측을 하는 상태이다. 모델이 테스트 데이터 뿐만 아니라 트레이닝 데이터에 대해서도 제대로 수행되지 않으면 그것은 과소적합이다.

[0109] 본 발명의 일 실시예는 메트릭 기반 PFS 및 ML 기반 PFS의 두 가지 접근 방식을 다룬다. 본 발명에서는 SVM 모델을 ML 모델로 간주한다. SVM 모델을 배치함으로써 선형 및 다항식 SVM ML 기반 PFS의 정확도가 측정된다. 컴퓨터 시뮬레이션을 통해 ML 기반 PFS 스케줄링의 성능은 대부분의 경우 기존 PFS의 성능에 거의 근접하는 것으로 나타났다. 마찬가지로, 얻어진 결과로부터 다항식 SVM 방법이 선형 SVM 방법보다 더 잘 예측한다는 것을 확인할 수 있다. 정확도에 대한 시뮬레이션 매개 변수들의 효과가 또한 조사되었는데, 예를 들어, ML 기반 PFS는 더 높은 T 값에 대해 더 정확하게 예측한다. 마찬가지로, 선형 및 다항식 SVM 모델에 의해 만들어진 예측은 타임 슬롯에 따라 달라진다. 또한, 선형 및 다항식 SVM 모델에 의해 이루어진 예측은 타임 슬롯의 값이 증가함에 따라 증가한다는 것을 알 수 있다. 그러나, 트레이닝 샘플들의 일정한 한계 이후 예측 값은 거의 포화 상태이다. 트레이닝 샘플들의 수는 컴퓨터 성능의 제한적 특성으로 인해 특정 한계까지 증가할 수 있다.

[0110] 또한, 다항식 SVM 방법에서, 예측 값은 시뮬레이션에서 사용한 다항식 함수의 차수에 따라 변할 수 있다. 사용한 데이터의 경우 다항식 SVM 방법이 더 높은 다항식 차수에 대해 더 잘 예측한다는 것이 확인되었다. 또한 더 잘 예측할 수 있는 다항식의 차수는 시스템에 있는 특징들의 수와 그들 사이의 관계에 따라 달라진다는 사실을 알 수 있다.

[0111] 도 15는 본 발명의 일 실시예에 의한 무선 통신 네트워크에서 기계 학습을 이용한 패킷 스케줄링 장치의 블록도이고, 도 16은 본 발명의 일 실시예에 의한 무선 통신 네트워크에서 기계 학습을 이용한 패킷 스케줄링 방법의 흐름도이다.

[0112] 도 15에 도시된 본 발명의 일 실시예에 의한 무선 통신 네트워크에서 기계 학습을 이용한 패킷 스케줄링 장치(1500)는, 채널 할당과 관련된 트레이닝 데이터에 기반하여 기계 학습 기반 비례 공정 스케줄링(PFS: Proportional Fair Scheduling)을 수행하여 이동국(MS1 내지 MSn)을 사용하는 사용자를 채널에 할당하기 위한 채널 할당 분류 모델을 형성하기 위한 다항식 서포트 벡터 머신 기반 비례 공정 스케줄러(1504), 채널 할당과 관련된 테스트 데이터를 획득하기 위한 테스트 데이터 획득부(1502), 및 사용자-채널 할당의 결과에 대한 성능

평가를 수행하기 위한 성능 평가부(1506)를 포함한다.

[0113] 상기와 같이 구성된 본 발명의 일 실시예에 의한 무선 통신 네트워크에서 기계 학습을 이용한 패킷 스케줄링 장치의 동작을 도 16에 도시된 흐름도에 기반하여 설명하기로 한다.

[0114] 도 15 및 도 16을 참조하면, 단계 S1600에서, 다항식 서포트 벡터 머신 기반 비례 공정 스케줄러(1504)는 채널 할당과 관련된 트레이닝 데이터에 기반하여 다항식 서포트 벡터 머신 기반 비례 공정 스케줄링(PFS: Proportional Fair Scheduling)을 수행하여 이동국(MS1 내지 MSn)을 사용하는 사용자를 채널에 할당하기 위한 채널 할당 모델을 형성한다.

[0115] 본 발명의 일 실시예에서, 상기 채널 할당과 관련된 트레이닝 데이터는, 채널 할당 모델을 형성하기 위한 채널의 전송 속도 또는 채널의 처리 능력과 같은 채널 정보, 채널 할당 모델을 형성하기 위한 이전 타임 슬롯까지의 사용자의 평균 처리량, 및 채널 할당 모델을 형성하기 위한 이전 타임 슬롯의 선택된 사용자 중 적어도 하나를 포함한다. 상기 채널 할당과 관련된 트레이닝 데이터는 비례 공정 스케줄링과 관련된 수학식에 기반하여 계산되는 트레이닝 데이터이거나, 실험을 통해 검증된 사용자와 채널을 할당하는 미리 알려져 있는 비례 공정 스케줄링과 관련된 채널 할당 트레이닝 데이터일 수 있다.

[0116] 단계 S1602에서, 테스트 데이터 획득부(1502)는 이동국(MS1 내지 MSn)으로부터 수신되는 정보에 기반하여 채널 할당과 관련된 테스트 데이터를 획득한다.

[0117] 본 발명의 일 실시예에서, 상기 채널 할당과 관련된 테스트 데이터는, 사용자-채널 할당을 결정하는데 사용되는 채널의 전송 속도 또는 채널의 처리 능력과 같은 채널 정보, 사용자-채널 할당을 결정하는데 사용되는 이전 타임 슬롯까지의 사용자의 평균 처리량, 및 사용자-채널 할당을 결정하는데 사용되는 이전 타임 슬롯의 선택된 사용자 중 적어도 하나를 포함한다.

[0118] 단계 S1604에서, 다항식 서포트 벡터 머신 기반 비례 공정 스케줄러(1504)는 상기 테스트 데이터를 상기 채널 할당 모델의 입력으로 하여 사용자-채널 할당을 결정한다.

[0119] 단계 S1606에서, 성능 평가부(1506)는, 사용자-채널 할당의 결과에 대한 성능(지연) 평가를 수행한다.

[0120] 단계 S1608에서, 성능 평가부(1506)는, 상기 성능 평가 결과, 사용자-채널 할당을 결정하기까지 소정값 이하의 지연이 발생하는 지를 판단한다.

[0121] 사용자-채널 할당을 결정하기까지 소정값보다 큰 지연이 발생하는 경우, 단계 S1610에서, 성능 평가부(1506)는 상기 다항식 서포트 벡터 머신 기반 비례 공정 스케줄러의 다항식의 차수를 조정하여, 다항식 서포트 벡터 머신 기반 비례 공정 스케줄러(1504)가 조정된 다항식의 차수에 기반하여 채널 할당 모델을 형성하게 한다.

[0122] 사용자-채널 할당에 소정값 이하의 지연이 발생하는 경우, 단계 S1612에서, 성능 평가부(1506)는 상기 다항식 서포트 벡터 머신 기반 비례 공정 스케줄러(1504)에 의해 결정된 사용자-채널 할당 결과를 최종 사용자-채널 할당 결과로서 출력한다.

[0123] 이상 본 발명을 구체적인 실시예를 통하여 상세하게 설명하였으나, 이는 본 발명을 구체적으로 설명하기 위한 것으로, 본 발명은 이에 한정되지 않으며, 본 발명의 기술적 사상 내에서 당 분야의 통상의 지식을 가진 자에 의해 그 변형이나 개량이 가능함은 명백하다고 할 것이다.

[0124] 본 발명의 단순한 변형 내지 변경은 모두 본 발명의 영역에 속하는 것으로, 본 발명의 구체적인 보호 범위는 첨부된 청구범위에 의하여 명확해질 것이다.

부호의 설명

[0125] 1500 : 스케줄러 1502 : 테스트 데이터 획득부

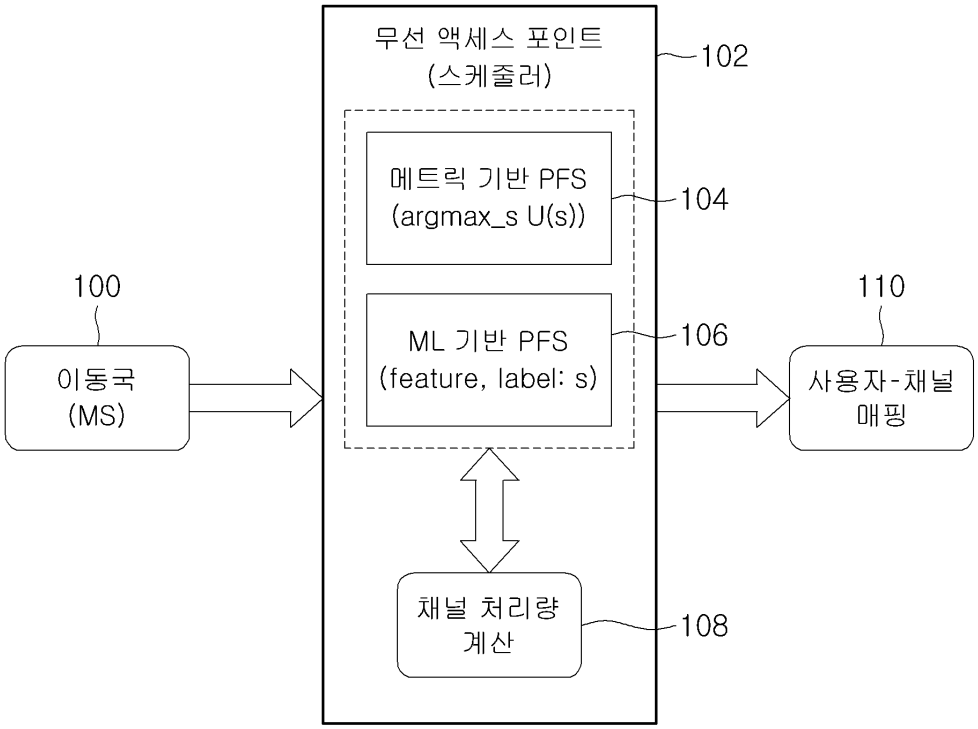
1504 :다항식 서포트 벡터 머신 기반 PFS

1506 : 성능 평가부

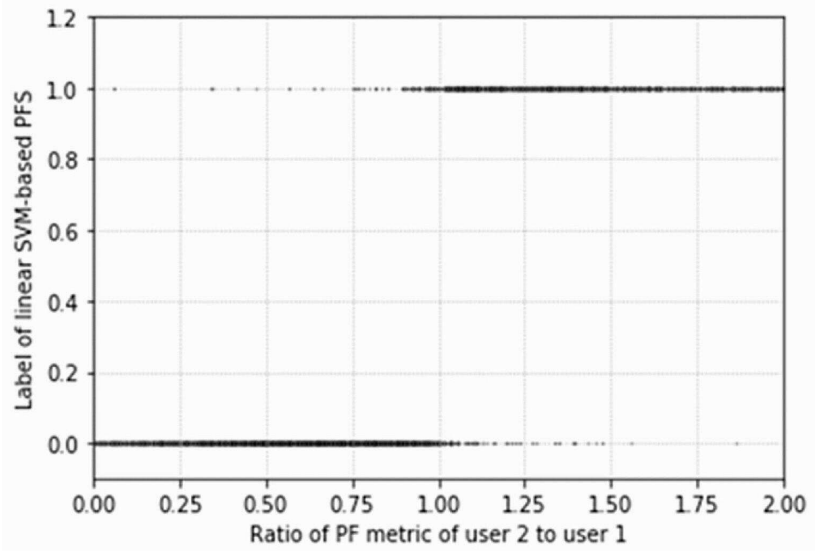
MS1 내지 MSn : 이동국

도면

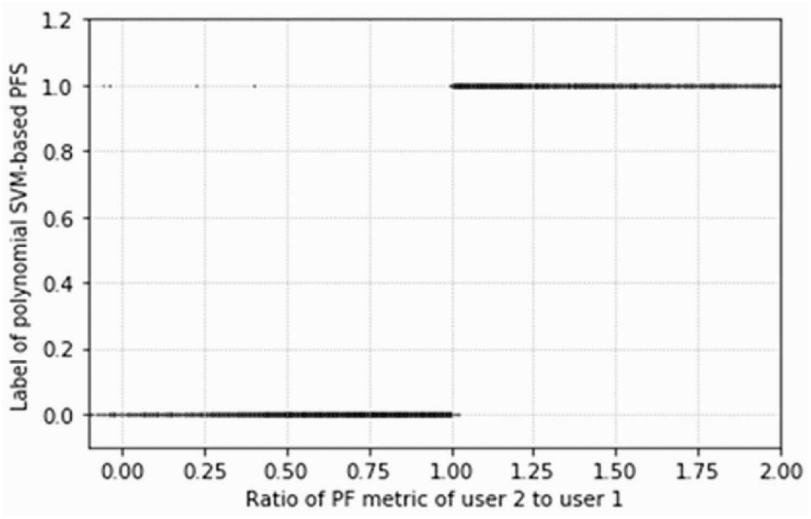
도면1


무선 액세스 포인트
(스케줄러)
102
메트릭 기반 PFS
(argmax_s U(s))
104
ML 기반 PFS
(feature, label: s)
106
채널 처리량
계산
108
100
이동국
(MS)
110
사용자-채널
매핑

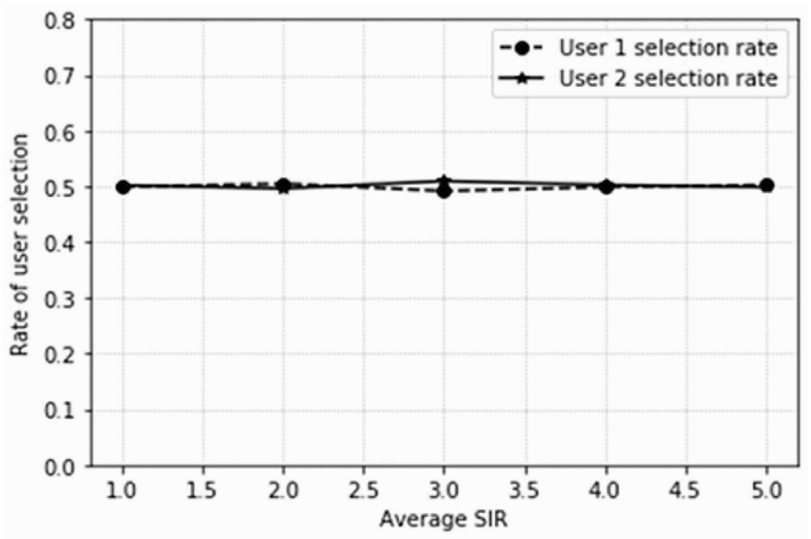
도면2


Label of linear SVM-based PFS
1.2
1.0
0.8
0.6
0.4
0.2
0.0
0.00
0.25
0.50
0.75
1.00
1.25
1.50
1.75
2.00
Ratio of PF metric of user 2 to user 1

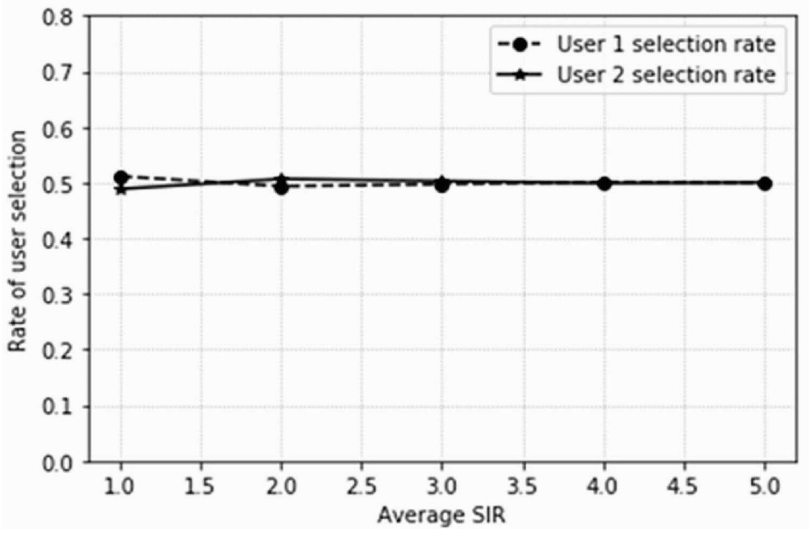
도면3


Label of polynomial SVM-based PFS
Ratio of PF metric of user 2 to user 1
0.0
0.2
0.4
0.6
0.8
1.0
1.2
0.00
0.25
0.50
0.75
1.00
1.25
1.50
1.75
2.00

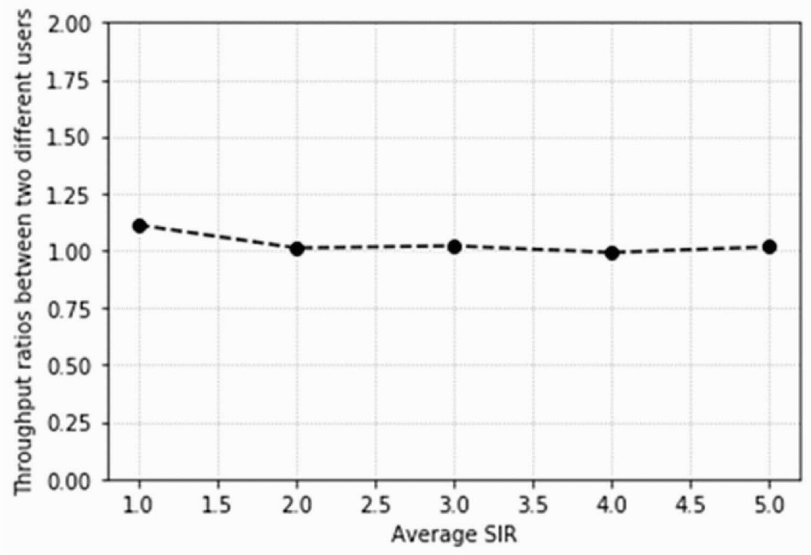
도면4


User 1 selection rate
User 2 selection rate
Rate of user selection
Average SIR
0.0
0.1
0.2
0.3
0.4
0.5
0.6
0.7
0.8
1.0
1.5
2.0
2.5
3.0
3.5
4.0
4.5
5.0

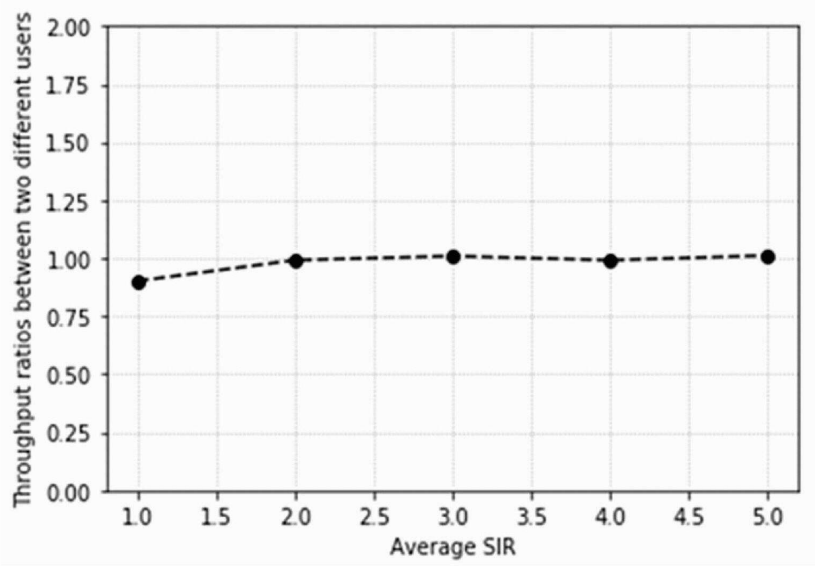
도면5


User 1 selection rate
User 2 selection rate
Rate of user selection
Average SIR
0.0
0.1
0.2
0.3
0.4
0.5
0.6
0.7
0.8
1.0
1.5
2.0
2.5
3.0
3.5
4.0
4.5
5.0

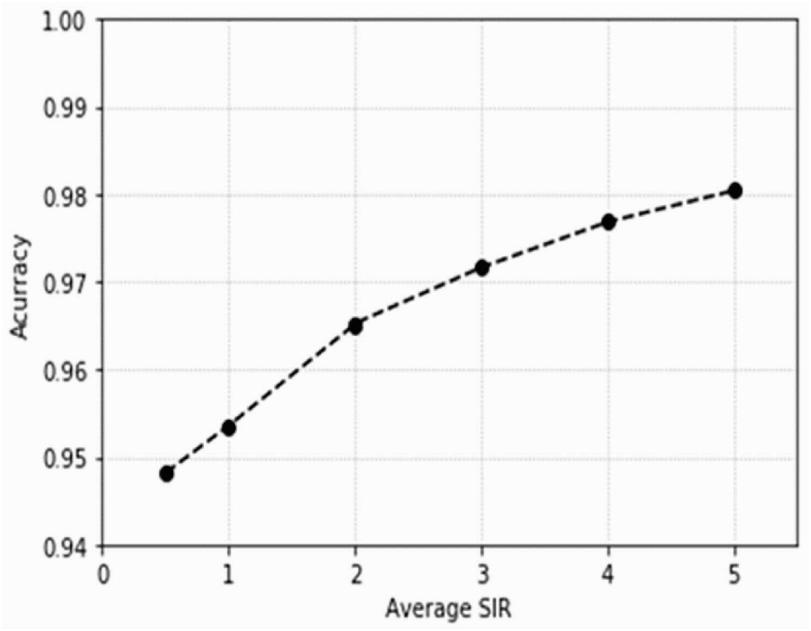
도면6


Throughput ratios between two different users
2.00
1.75
1.50
1.25
1.00
0.75
0.50
0.25
0.00
1.0
1.5
2.0
2.5
3.0
3.5
4.0
4.5
5.0
Average SIR

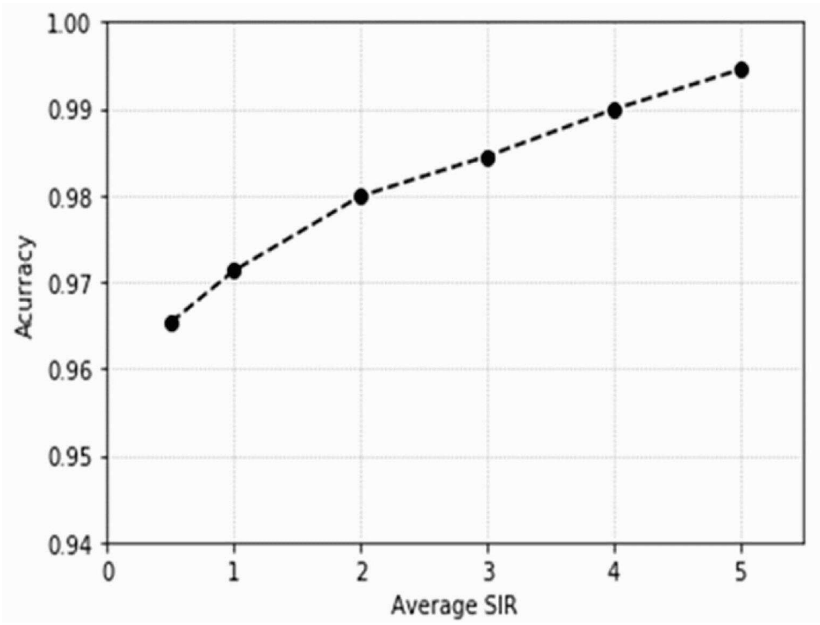
도면7


Throughput ratios between two different users
2.00
1.75
1.50
1.25
1.00
0.75
0.50
0.25
0.00
1.0
1.5
2.0
2.5
3.0
3.5
4.0
4.5
5.0
Average SIR

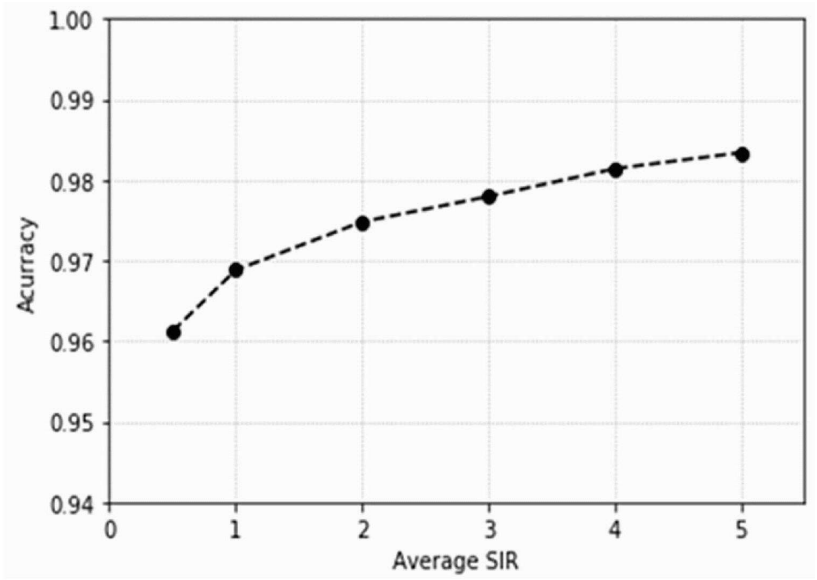
도면8


1.00
0.99
0.98
0.97
0.96
0.95
0.94
Acurracy
0
1
2
3
4
5
Average SIR

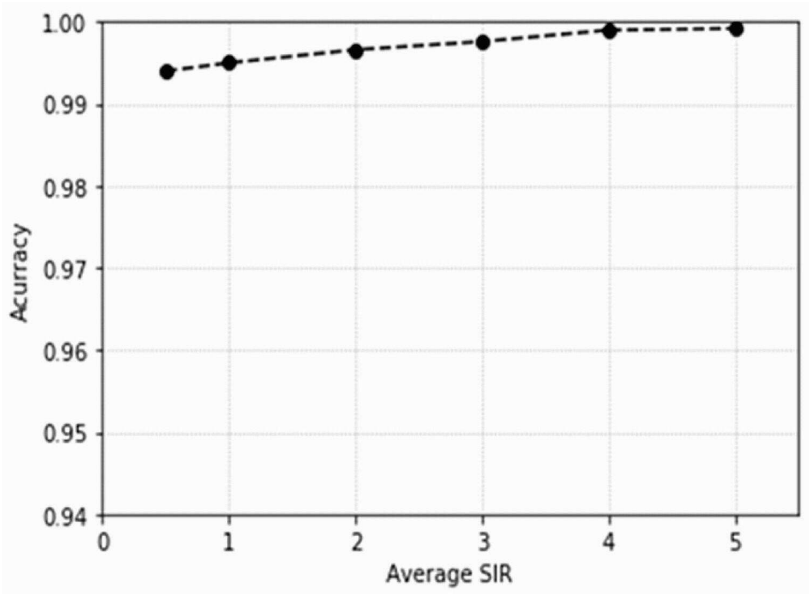
도면9


1.00
0.99
0.98
0.97
0.96
0.95
0.94
Acurracy
0
1
2
3
4
5
Average SIR

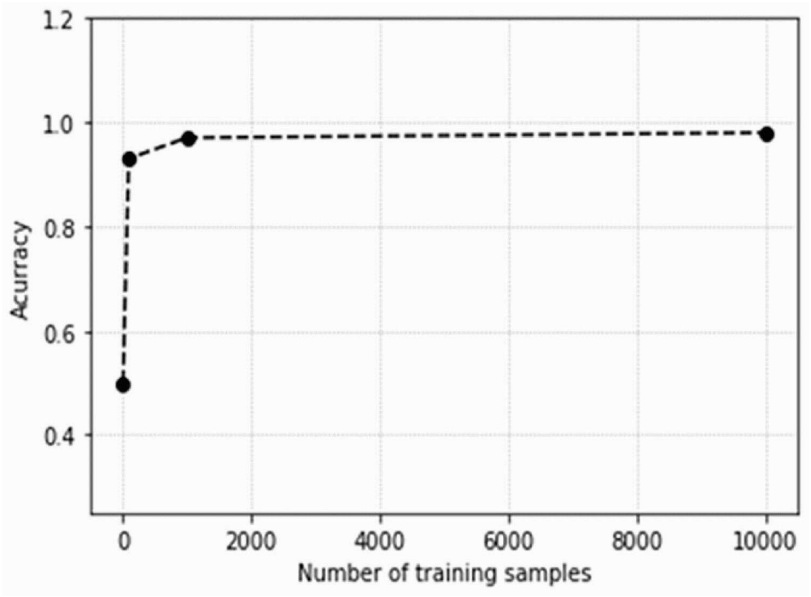
도면10


1.00
0.99
0.98
0.97
0.96
0.95
0.94
Acurracy
0
1
2
3
4
5
Average SIR

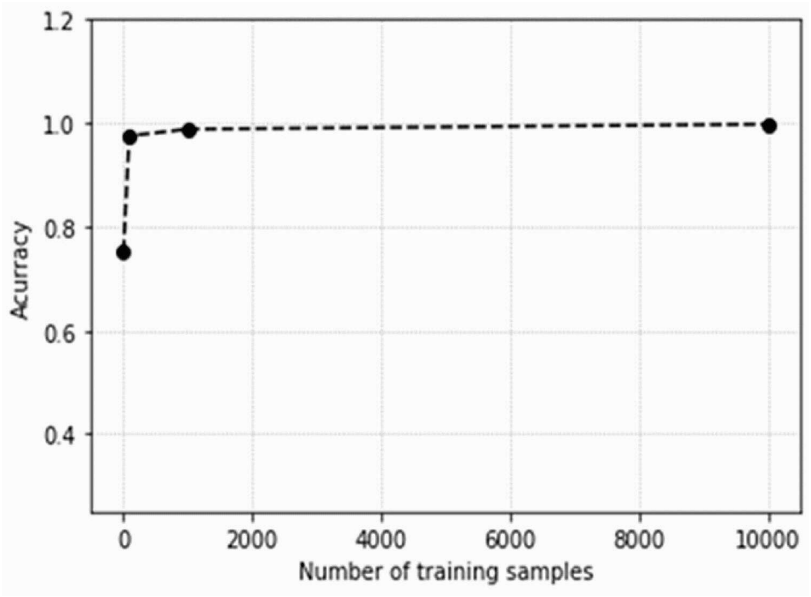
도면11


1.00
0.99
0.98
0.97
0.96
0.95
0.94
Acurracy
0
1
2
3
4
5
Average SIR

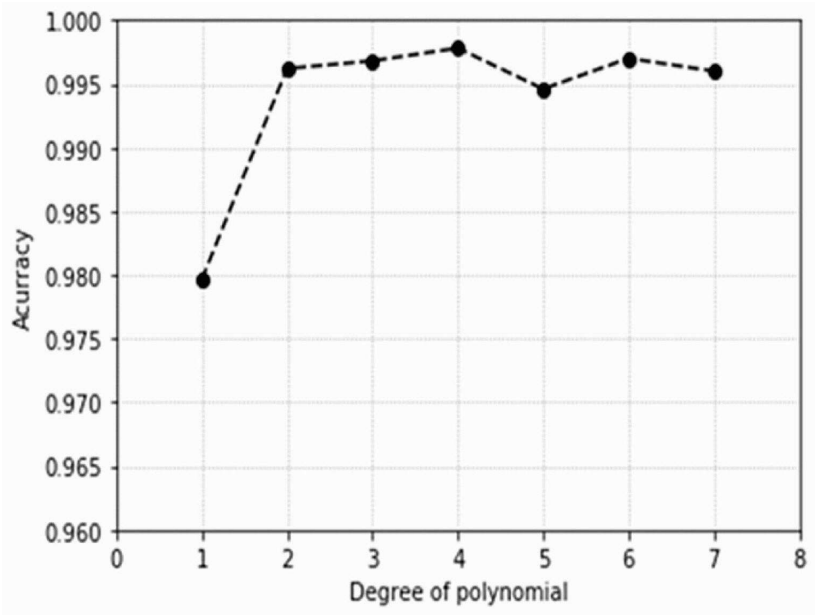
도면12


1.2
1.0
0.8
0.6
0.4
Acurracy
0
2000
4000
6000
8000
10000
Number of training samples

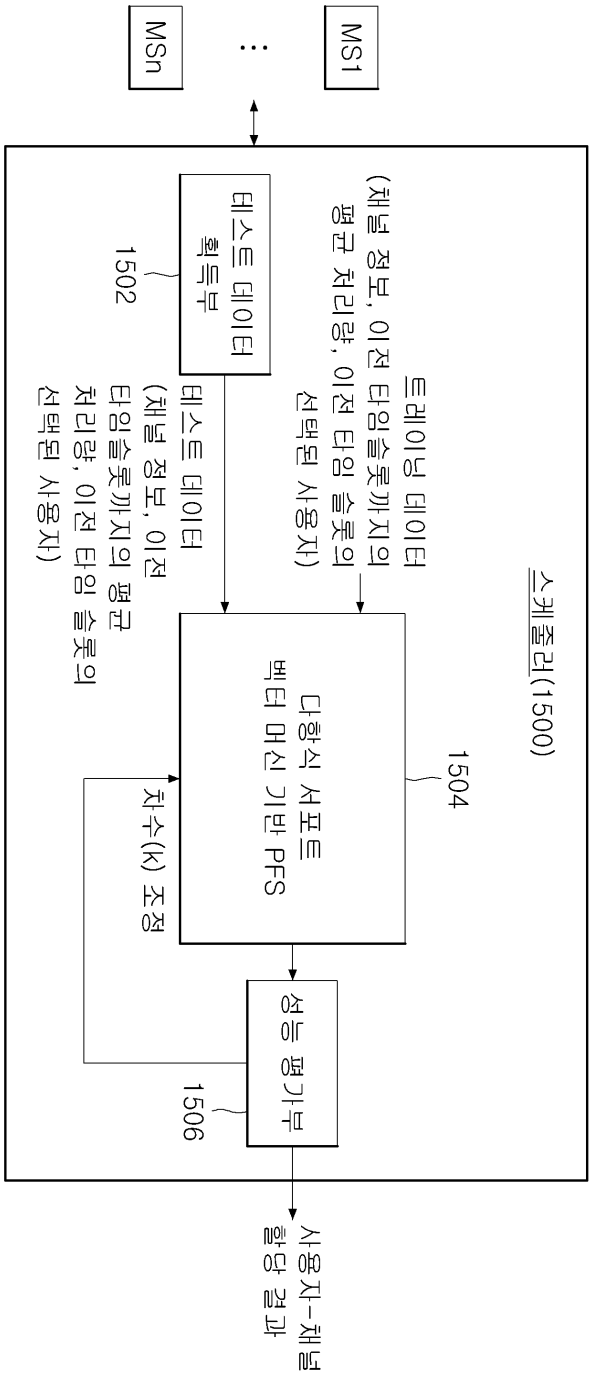
도면13


1.2
1.0
0.8
0.6
0.4
Acurracy
0
2000
4000
6000
8000
10000
Number of training samples

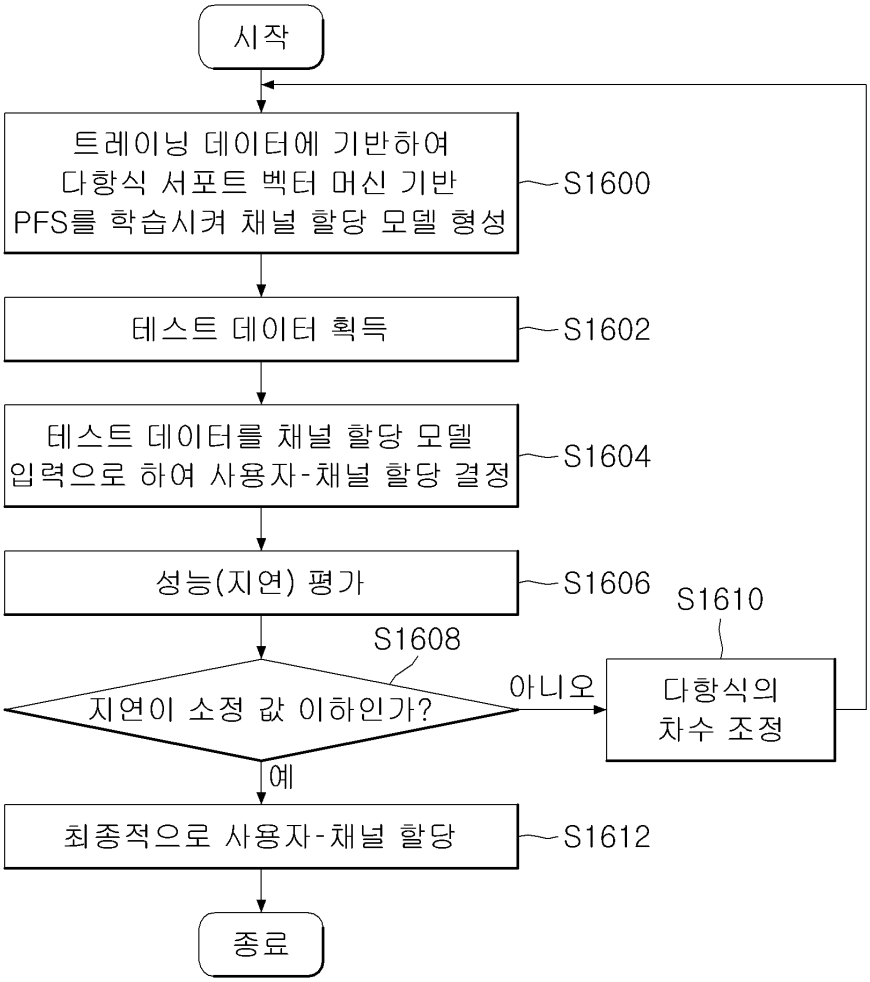
도면14


1.000
0.995
0.990
0.985
0.980
0.975
0.970
0.965
0.960
Acurracy
0
1
2
3
4
5
6
7
8
Degree of polynomial

도면15


MS1
MSn
스케줄러(1500)
트레이닝 데이터
(채널 정보, 이전 타임슬롯까지의
평균 처리량, 이전 타임 슬롯의
선택된 사용자)
테스트 데이터
획득부
1502
테스트 데이터
(채널 정보, 이전
타임슬롯까지의 평균
처리량, 이전 타임 슬롯의
선택된 사용자)
다항식 서포트
벡터 머신 기반 PFS
1504
차수(k) 조정
성능 평가부
1506
사용자-채널
할당 결과

도면16


시작
트레이닝 데이터에 기반하여 다항식 서포트 벡터 머신 기반 PFS를 학습시켜 채널 할당 모델 형성
S1600
테스트 데이터 획득
S1602
테스트 데이터를 채널 할당 모델 입력으로 하여 사용자-채널 할당 결정
S1604
성능(지연) 평가
S1606
S1608
지연이 소정 값 이하인가?
아니오
S1610
다항식의 차수 조정
예
최종적으로 사용자-채널 할당
S1612
종료