

강의개요

Shrinkage Methods and Tree Ensembles for High-dimensional Sparse Data

생물정보학에서 다루는 많은 데이터들은 변수의 개수는 많지만 표본 크기는 “상대적으로 작은” 고차원 희박 데이터(high-dimensional sparse data)이다. 예를 들어 마이크로어레이나 RNA 시퀀싱으로 얻어지는 유전자 발현 데이터는 수천 ~ 수만 개의 유전자에 대한 발현 정보를 가지고 있지만 표본의 크기는 대부분 수백 ~ 수만에 지나지 않는다.

본 강의에서는 고차원 희박 데이터가 기계학습에 어떠한 악영향을 미치는지를 직관적으로 설명하고, 이러한 데이터를 분석하는 데 널리 사용되는 shrinkage 방법과 tree ensemble에 대해 설명한다. 선형회귀 및 로지스틱 회귀 기반의 shrinkage 방법이 어떠한 전략으로 고차원 희박 데이터 문제를 해결하는지 설명하고, 그 구체적인 활용 방법에 대해 강의한다. 또한, 고차원 희박 데이터를 다룰 수 있는 비선형 방법인 결정트리(decision tree) 기반의 tree ensemble도 상세히 다룬다.

강의는 다음의 내용을 포함한다:

- Bias-Variance Trade-Off
- 고차원 희박 데이터의 문제점
- Shrinkage 방법 (Ridge, Lasso, Elastic Net)
- Tree Ensemble (Bagging, Random Forest, Boosting)

*참고강의교재:

An Introduction to Statistical Learning: with Applications in R (Springer, 2013)

*교육생준비물:

노트북 (동영상 강의 시청용)

* 강의 난이도: 초급

* 강의: 황규백 교수 (승실대학교 컴퓨터학부)

Curriculum Vitae

Speaker Name: Kyu-Baek Hwang, Ph.D.



► Personal Info

Name Kyu-Baek Hwang
Title Professor
Affiliation Soongsil University

► Contact Information

Address 369 Sangdo-ro, Dongjak-gu, Soongsil University, Seoul 06978
Email kbhwang@ssu.ac.kr

Research Interests: Machine learning and bioinformatics

Educational Experience

1997 B.S.E. in Computer Engineering, Seoul National University, Korea
1999 M.S.E. in Computer Engineering, Seoul National University, Korea
2005 Ph.D. in Computer Science and Engineering, Seoul National University, Korea

Professional Experience

2004 Short-term Visiting Scholar, Children's Hospital Boston, USA
2012 Visiting Research Associate, Boston Children's Hospital, USA
2006 - Professor, Soongsil University, Korea

Selected Publications (5 maximum)

1. Hwang, K.-B.+, Lee, I.-H.+, Li, H., Won, D.-G., Hernandez-Ferrer, C., Negron, J.A., and Kong, S.W., Comparative analysis of whole-genome sequencing pipelines to minimize false negative findings, *Scientific Reports*, vol. 9, p. 3219, 2019.
2. Li, H.+, Park, J.+, Kim, H., Hwang, K.-B.*, and Paek, E.*, Systematic comparison of false-discovery-rate-controlling strategies for proteogenomic search using spike-in experiments, *Journal of Proteome Research*, vol. 16, no. 6, pp. 2231-2239, 2017.
3. Li, H., Joh, Y.S., Kim, H., Paek, E., Lee, S.-W., and Hwang, K.-B., Evaluating the effect of database inflation in proteogenomic search on sensitive and reliable peptide identification, *BMC Genomics*, vol., 17, no. Suppl 13, p. 3327, 2016.

4. Seok, H.-S., Song, T., Kong, S.W., and Hwang, K.-B., An efficient search algorithm for finding genomic-range overlaps based on the maximum range length, *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, vol. 12, no. 4, pp. 778-784, 2015.