Forslag til eksamenspensum

DAT8, NIS

Forår 2001

Nedenstående udgør en 'bruttoliste' af eksamensspørgsmål i kurset "Nye Teknologier indenfor Intelligente Systemer" (NIS) — også kendt under navnet "Machine Learning". Ca. 3/4 af nedenstående skal indgå i det endelige eksamenspensum.

Den relevante litteratur i forbindelse med nedenstående eksamensspørgsmål udgøres af kapitlerne 2, 3, 4, 5, 6, 8, 9, 10, 13 i Tom Mitchell's bog "Machine Learning" (se www.cs.auc.dk/education/dat8/). I nedenstående refererer 'ML' til denne bog.

Der gøres opmærksom på, at nedenstående liste ikke udgør en komplet liste af emner behandlet i kurset. De manglende emner udgøres af

- Introduktion til "Machine Learning" (kap. 1 i ML)
- EM-algoritmen (afsnit 6.12 i ML)
- Spilteori og multi-agent reinforcement learning (ekstra litteratur)

1 Niveau

Kursets formål er, at den enkelte studerende opnår viden om gængse metoder og algoritmer til automatisk maskinel indlæring på baggrund af data, herunder metoder og algoritmer til indlæring af hypoteser, som kan forklare givne fænomener ("target concepts"), og metoder og algoritmer til optimal adfærd, således at givne måltilstande opnås med mindst mulig omkostning.

Da dette emneområde er temmelig omfattende, har det derfor ikke været hensigten, at den enkelte studerende skulle opnå detaljeret kendskab til de behandlede emner, men derimod at opnå kendskab til området på et mere overordnet niveau, og specielt blev i stand til at vurdere de enkelte metoder og algoritmers anvendelighed til løsning af problemer under forskellige forudsætninger.

Derfor forventes den enkelte studerende til eksamen at kunne demonstrere overblik snarere end kendskab til detaljer vedrørende de i kurset berørte metoder

og algoritmer. For at demonstrere et sådant overblik, forventes den enkelte studerende, til hver af de berørte metoder og algoritmer, at kunne redegøre for en række generelle spørgsmål. Herunder hører f.eks. følgende spørgsmål:

- *When:* Hvornår er denne metode velegnet?
- *Hypothesis space:* Hvordan beskrives hypotese-rummet for denne metode, og hvordan repræsenteres hypoteserne?
- *Robustness:* Er denne metode robust overfor støjfyldte data?
- *Incomplete data:* Kan denne metode håndtere ufuldstændige cases (dvs. cases, hvor én eller flere attributværdier mangler)?

2 Pensumliste

Nedenfor følger en liste af (forslag til) eksamensspørgsmål, hvor der til hvert spørgsmål er angivet en række underemner (inkluderende ovenstående generelle spørgsmål, hvor disse er relevante), som udgør de begreber/spørgsmål, der anses for essentielle. Emner berørt i bogen (ML), som ikke indgår i nedenstående anses for mindre væsentlige, specielle og/eller mere avancerede end eksaminanden forventes at kunne redegøre fyldestgørende for.

Emnerne og de tilhørende underemner er angivet på engelsk af hensyn til konsistens med den i bogen (ML) anvendte terminologi.

1. Concept Learning
   - target function
   - training examples
   - hypothesis space
   - inductive learning hypothesis
   - general-to-specific ordering
   - FIND-S
   - version space
   - CANDIDATE-ELIMINATION
   - inductive bias
   - futility of unbiased learning
2. Decision Tree Learning

- definition (representation and representational power)
- hypothesis space
- when to consider decision-tree learning
- construction algorithm (ID3)
- attribute selection (information gain)
- inductive bias, Occam's razor
- robustness to noisy data
- overfitting and pruning
- decision trees vs. sets of rules
- ability to handle incomplete data

3. Singlelayer Neural Networks

- definition (representation)
- hypothesis space
- when to consider neural networks
- perceptron
- linear separability, representational power
- perceptron training
- gradient descent and delta rule
- incremental gradient descent

4. Multilayer Neural Networks

- definition (representation)
- hypothesis space
- when to consider neural networks
- sigmoid threshold unit (why?)
- backpropagation
- convergence and local minima
- expressive capability (representational power)
- inductive bias
- why hidden layer?
- overfitting, stopping criterion

5. Evaluating Hypotheses

- motivation
- sample error and true error
- confidence interval
- bias
- mean and variance
- error estimation
- Binomial distribution
- Normal distribution
- two-sided and one-sided bounds on confidence interval
- central limit theorem
- hypothesis testing
- paired t-test
- comparing learning algorithms

6. Bayesian Learning: MAP & ML

- Bayes' rule
- product rule, sum rule, total probability rule
- MAP, ML hypotheses
- MAP learning
- relation to concept learning
- minimum description length principle (Occam's razor)
- Bayes optimal classifier

7. Naive Bayes Learner/Classifier & Bayesian Networks

- definition of naive Bayes principle
- hypothesis space
- when to consider naive Bayes or Bayesian networks
- naive Bayes learner/classifier
- definition of Bayesian networks
- conditional independence
- learning Bayesian networks

- robustness to noisy data
- ability to handle incomplete data

8. Instance-Based Learning

   - k-nearest neighbor learning
   - inductive bias of k-nearest neighbor
   - distance-weighted k-nearest neighbor
   - curse of dimensionality
   - locally weighted regression
   - radial basis function networks
   - case-based reasoning
   - lazy vs. eager learning
   - robustness to noisy data
   - ability to handle incomplete data

9. Genetic Algorithms

   - motivation, inspiration
   - the steps of a genetic algorithm
   - hypothesis space
   - representing hypotheses
   - genetic operators
   - fitness selection and crowding
   - genetic programming
   - robustness to noisy data
   - ability to handle incomplete data

10. Learning Sets of Rules

    - sequential covering algorithm
    - sequential or simultaneous covering of data (e.g. compare with decision tree learning)
    - performance measure for rules
    - propositional rules
    - first-order rules

   - propositional vs. first-order rules (expressive power)
   - deduction (resolution rule)
   - induction as inverted deduction
   - first-order resolution

11. Reinforcement Learning

    - when to consider reinforcement learning
    - definition of the reinforcement learning problem
    - Markov decision processes (MDPs)
    - learning problem in MDPs
    - reward function
    - (optimal) value function
    - (optimal) policy
    - Q function
    - Q learning
    - nondeterministic rewards and actions
    - nondeterministic value function, Q function, Q learning

Uffe Kjærulff, 20. maj 2001