

**K-NEAREST NEIGHBOUR (KNN) UNTUK MENDETEKSI GANGGUAN JARINGAN
KOMPUTER PADA INTRUSION DETECTION DATASET**

Bekti Maryuni Susanto

Program Studi Manajemen Informatika, AMIK "BSI Yogyakarta"
Jl. RingRoad Barat Ambarketawang Gamping Sleman Yogyakarta
bekti.bms@bsi.ac.id

Abstract

Internet increasing is also exponentially increasing intrusion or attacks by crackers exploit vulnerabilities in Internet protocols, operating systems and software applications. Intrusion or attacks against computer networks, especially the Internet has increased from year to year. Intrusion detection systems into the main stream in the information security. The main purpose of intrusion detection system is a computer system to help deal with the attack. This study presents k-nearest neighbour algorithm to detect computer network intrusions. Performance is measured based on the level of accuracy, sensitivity, precision and specificity. Dataset used in this study is a dataset KDD99 intrusion detection system. Dataset is composed of two training data and testing data. From the experimental results obtained by the accuracy of k-nearest neighbour algorithm is about 79,36%.

Keyword: *k-nearest neighbour, intrusion detection*

1. PENDAHULUAN

Internet yang meningkat secara eksponensial meningkatkan juga gangguan atau serangan yang dilakukan oleh cracker mengeksploitasi kelemahan pada protokol internet, sistem operasi dan software aplikasi. Gangguan atau serangan terhadap jaringan komputer khususnya internet mengalami peningkatan dari tahun ke tahun. Berdasarkan laporan dari Kaspersky Lab jumlah serangan melalui browser internet sejumlah 23.680.646 pada tahun 2007, meningkat menjadi 73.619.767 pada tahun 2009 dan meningkat lagi menjadi 580.371.937 pada tahun 2010. *Internet browser* menjadi alat utama dalam menyebarkan program-program malicious diantara sebagian besar pengguna komputer pada tahun 2010. Algoritma *Kaspersky Security Network (KSN)* hanya mampu mendeteksi serangan web sebesar 60 % (Gostev & Namestnikov, 2011).

Intrusion detection adalah proses memonitor kejadian pada sistem

komputer atau jaringan dan menganalisanya untuk memberikan tanda insiden yang mungkin, yang mana yang merupakan pelanggaran atau mendekati pelanggaran sebuah kebijakan keamanan komputer, kebijakan penggunaan yang disetujui atau praktik keamanan standar. *Intrusion prevention* adalah proses untuk menampilkan *intrusion detection* dan berusaha untuk menghentikan kejadian yang mungkin dideteksi. *Intrusion detection* dan prevention system adalah perhatian utama dalam mengidentifikasi kejadian, mencatat informasinya, berusaha untuk menghentikannya dan melaporkannya kepada administrator keamanan. Sebagai tambahan organisasi menggunakan *intrusion detection* dan prevention system (IDPS) untuk tujuan lain, seperti mengidentifikasi permasalahan kebijakan keamanan, mendokumentasikan perlakuan yang ada, dan menghambat individu dalam melakukan pelanggaran kebijakan

keamanan. IDPS menjadi tambahan yang perlu terhadap infrastruktur keamanan bagi setiap organisasi (Scarfone & Mell, 2007).

Intrusion detection system menjadi aliran utama di dalam keamanan informasi. Tujuan utama *intrusion detection system* adalah membantu sistem komputer untuk menangani serangan.

Ada dua tipe *intrusion detection system* berdasarkan tipe operasi yang digunakan untuk mendeteksi gangguan, *anomaly detection system* dan *misuse detection*. *Anomaly detection system* membuat database tingkah laku normal dan penyimpangannya dari tingkah laku normal yang terjadi, sebuah peringatan dipicu oleh sebuah adanya gangguan. *Misuse detection system* menyimpan pola serangan yang telah terdefinisi sebelumnya di dalam sebuah database jika situasi dan data yang mirip terjadi diklasifikasi sebagai serangan. Berdasarkan sumber data IDS diklasifikasi menjadi *IDS host based* dan *network based*. *IDS network based* menganalisa paket secara individual yang melalui jaringan. *IDS host based* menganalisa aktivitas pada sebuah komputer tunggal atau *host* (Neethu, 2012).

Sebagian besar IDS saat ini menggunakan sistem berbasis rule atau pakar. Kekuatannya sangat tergantung pada kemampuan personel keamanan yang mengembangkan IDS. Dahulunya, IDS hanya bisa mendeteksi tipe serangan yang diketahui dan sekarang cenderung membangkitkan alarm false positif. Hal ini menyebabkan penggunaan teknik *intelligence* yang dikenal sebagai data mining ataupun *machine learning* sebagai alternatif kemampuan manusia yang mahal dan berat. Teknik ini secara otomatis mempelajari data atau mengekstrak pola yang bermanfaat dari data sebagai referensi profil tingkah laku normal atau

serangan dari data yang ada untuk klasifikasi trafik jaringan selanjutnya (Olusola et al., 2010). *Machine learning* adalah sebuah bidang studi yang menyediakan komputer dengan kemampuan pembelajaran dari pengalaman sebelumnya. *Machine learning* berdasarkan analisa data statistik yang sangat besar dan beberapa algoritma dapat menggunakan pola yang ditemukan pada data sebelumnya untuk membuat keputusan tentang data baru (Tavallae et al., 2009).

2. LANDASAN TEORI

2.1. Intrusion Detection System

Intrusion detection adalah proses memonitor kejadian yang terjadi pada sistem komputer atau jaringan dan menganalisanya untuk menandai kejadian yang mungkin, yang mana yang merupakan pelanggaran atau mendekati pelanggaran sebuah kebijakan keamanan komputer, kebijakan penggunaan yang disetujui atau praktik keamanan standar. Insiden mempunyai banyak penyebab, seperti malware, *attacker* yang mendapatkan *unauthorized access* ke sistem melalui *Internet*, dan pengguna yang sah yang menyalahgunakan hak akses mereka atau usaha untuk mendapatkan hak akses tambahan dimana mereka tidak berhak. Meskipun banyak insiden yang secara alami adalah malicious, banyak kejadian yang lain yang bukan malicious, sebagai contoh, orang yang salah mengetikkan alamat komputer dan usaha yang tidak sengaja untuk menghubungkan ke sistem yang berbeda tanpa hak.

Intrusion detection system adalah sebuah *software* yang secara otomatis mendeteksi gangguan. *Intrusion detection system* biasanya digunakan bersama-sama dengan *intrusion prevention system*, yaitu sebuah *software* yang mempunyai kemampuan seperti *intrusion detection system* dan dapat berusaha

menghentikan kejadian yang mungkin. Pada beberapa referensi istilah *intrusion detection and prevention system* (IDPS) digunakan untuk menggantikan keduanya. IDS utamanya fokus pada mengidentifikasi kejadian yang mungkin. Sebagai contoh, IDS dapat mendeteksi seorang *attacker* secara sukses mengganggu sebuah sistem dengan meneksplotasi kelemahan di dalam sistem. IDS kemudian membuat laporan kepada administrator keamanan, yang dapat secara cepat menginisiasi tindakan tanggapan kejadian untuk meminimalkan kerusakan yang disebabkan oleh kejadian tersebut. IDS dapat juga mencatat informasi yang dapat digunakan oleh administrator keamanan (Scarfone & Mell, 2007).

Teknologi IDS menggunakan berbagai macam metodologi dalam mendeteksi insiden, yaitu *signature-based detection*, *anomaly-based detection* dan *stateful protocol analysis*. *Signature-based detection* sering juga disebut *misuse detection*. *Signature* adalah sebuah pola yang berhubungan dengan ancaman yang sudah diketahui. *Signature based detection* adalah sebuah proses membandingkan *signature* dengan kejadian yang diamati untuk mengidentifikasi insiden yang mungkin (Scarfone & Mell, 2007). *Conoth signature* adalah sebuah telent yang mencoba dengan *username root* yang melanggar kebijakan keamanan organisasi, sebuah email dengan subject free picture dan sebuah file lampiran freepics.exe yang tergolong sebagai malware, dan sebuah *log entry* sistem operasi dengan nilai kode status 645, yang mengindikasikan audit host dinonaktifkan. *Signature-based detection* sangat efektif mendeteksi ancaman yang sudah diketahui tetapi sangat tidak efektif untuk mendeteksi ancaman yang sebelumnya tidak diketahui, ancaman menyamar dengan teknik pengelabuan, dan banyak variasi ancaman yang sudah diketahui. Sebagai

contoh, jika *attacker* memodifikasi *malware* pada contoh sebelumnya menggunakan nama file freepics2.exe, sebuah *signature* mencari freepics.exe tidak akan cocok.

Signature-based detection adalah metode paling sederhana karena metode ini hanya membandingkan unit aktivitas saat ini, seperti paket atau *log entry*, dengan daftar *signature* menggunakan operasi perbandingan string. Metodologi *signature-based detection* memiliki pemahaman yang sedikit tentang jaringan atau protokol aplikasi yang banyak dan tidak dapat melacak dan memahami kondisi komunikasi yang kompleks. Sebagai contoh, metode ini tidak dapat memasang permintaan dengan respon yang bersesuaian, seperti mengetahui bahwa permintaan ke *web server* untuk halaman tertentu dibangkitkan sebuah respon dengan nilai kode status 403, berarti bahwa server menolak memenuhi permintaan. Metode ini juga kurang mampu mengingat permintaan sebelumnya ketika memproses permintaan saat ini. Keterbatasan ini mencegah metode *signature-based detection* dari mendeteksi serangan yang terdiri dari banyak kejadian jika tidak ada kejadian berisi indikasi yang jelas sebuah serangan.

Anomaly-based detection adalah proses membandingkan definisi aktivitas yang dikatakan normal dengan kejadian yang diamati untuk mengidentifikasi penyimpangan yang signifikan (Scarfone & Mell, 2007). IDS yang menggunakan *anomaly-based detection* mempunyai sebuah profil yang mewakili tingkah laku normal hal-hal seperti *user*, *host*, koneksi jaringan, atau aplikasi. Profil dikembangkan dengan memonitor karakteristik aktivitas khusus selama periode tertentu. Sebagai contoh, sebuah profil untuk jaringan mungkin menunjukkan bahwa aktivitas web terdiri atas rata-rata 13% *bandwidth*

jaringan pada batas internet selama beberapa jam hari kerja khusus. IDS menggunakan metode statistik untuk membandingkan karakteristik aktivitas saat ini dengan ambang batas profil yang berhubungan, seperti mendeteksi ketika aktivitas web terdiri dari *bandwidth* yang lebih signifikan dari pada yang diharapkan dan memberi tanda alarm kepada *administrator* tentang anomaly. Profil dapat dikembangkan untuk banyak atribut tingkah laku, seperti jumlah email yang dikirimkan oleh seorang user, jumlah login gagal yang dilakukan oleh seorang user dan tingkat penggunaan prosesor untuk host selama periode waktu tertentu.

Keuntungan utama *anomaly-based detection* adalah bahwa metode ini sangat efektif untuk mendeteksi ancaman yang tidak diketahui sebelumnya. Sebagai contoh, andaikan misal sebuah komputer terinfeksi tipe *malware* baru. *Malware* bisa mengkonsumsi sumber daya komputer, mengirimkan banyak email, mengawali koneksi jaringan yang banyak, dan menampilkan tingkah laku lain yang sangat berbeda dari profil komputer yang sudah ada. Sebuah profil awal dibangkitkan selama periode waktu (biasanya beberapa hari atau minggu) kadang-kadang disebut *training periode*. Profil untuk *anomaly-based detection* bisa statik atau dinamik. Setelah dibangkitkan, profil statik tidak dapat diubah kecuali IDS secara khusus diarahkan untuk membangkitkan profil baru. Profil dinamik diatur secara konstan ketika kejadian tambahan diamati. Karena sistem dan jaringan berubah sepanjang waktu, pengukuran yang sesuai tingkah laku normal juga berubah; sebuah profil statik bahkan bisa menjadi tidak akurat, sehingga perlu dibangkitkan kembali secara periodik. Profil dinamik tidak memiliki masalah ini, tetapi mereka rentan

terhadap usaha pengelabuan dari para *attacker*. Sebagai contoh, seorang *attacker* kadang-kadang menampilkan aktivitas malicious kecil, kemudian dengan perlahan meningkatkan frekuensi dan kuantitas aktivitas. Jika rata-rata perubahan cukup lambat IDS mungkin berpikir bahwa aktivitas malicious tersebut adalah aktivitas normal dan memasukkan ke dalam profil. Aktivitas malicious mungkin juga diamati selagi IDS membangun profil awal.

Metode yang ketiga yang sering digunakan dalam IDS adalah *stateful protocol analysis* yaitu membandingkan profil yang sudah ditentukan untuk masing-masing kondisi protocol dengan kejadian yang diamati untuk mengidentifikasi penyimpangan (Scarfone & Mell, 2007). Tidak seperti *anomaly-based detection*, yang menggunakan profil khusus host atau jaringan, *stateful protocol analysis* bersandar pada profil umum yang dikembangkan oleh vendor yang menentukan bagaimana protokol tertentu seharusnya dan tidak seharusnya digunakan. Kata *stateful* di dalam *stateful protocol analysis* berarti bahwa IDS mampu memahami dan melacak kondisi jaringan, *transport*, dan protokol aplikasi yang mempunyai catatan kondisi. Sebagai contoh, ketika user memulai sesi *File Transfer Protocol* (FTP), sesi diawali pada kondisi *unauthenticated*. User *unauthenticated* hanya dapat menampilkan beberapa perintah pada kondisi ini, seperti melihat informasi help atau penyediaan *username* dan *password*. Bagian penting memahami kondisi adalah mempasangkan permintaan dan respon, sehingga ketika usaha *authentication* FTP terjadi, IDS dapat menentukan sukses jika menemukan kode status pada respon yang bersesuaian. Setelah user diautentikasi secara sukses, sesi ada pada kondisi autentikasi dan user bisa

menampilkan banyak perintah. Menampilkan sebagian besar perintah ini pada sesi *unauthentication* dipertimbangkan sebagai mencurigakan, tetapi menampilkan perintah ini pada kondisi *authentication* dipertimbangkan sebagai jinak atau tidak berbahaya.

Kelamahan utama metode *stateful protocol analysis* adalah metode ini menggunakan sumber daya komputer yang sangat besar karena kompleksitas analisis dan menampilkan pelacakan kondisi untuk banyak sesi yang berurutan. Permasalahan serius lain adalah metode *stateful protocol analysis* tidak dapat mendeteksi serangan yang tidak melanggar karakteristik tingkah laku protokol yang umum disetujui, seperti menampilkan banyak tindakan yang tidak berbahaya selama periode waktu tertentu bisa menyebabkan denial of service.

Ada dua tipe IDS yang paling umum digunakan yaitu *Network-based* dan *Host-based*. *Network-based* memonitor trafik jaringan untuk segmen atau perangkat jaringan tertentu dan menganalisa aktivitas protokol jaringan dan aplikasi untuk mengidentifikasi aktivitas yang mencurigakan. Perangkat ini diterapkan pada batas antar jaringan, seperti dalam jarak untuk memagari firewall atau router, server VPN, *server remote access*, dan jaringan *wireless*. Tipe yang kedua adalah *Host-based*, yang memonitor karakteristik host tunggal dan kejadian yang terjadi di dalam host tersebut untuk aktivitas yang mencurigakan. Contoh tipe karakteristik IDS *host-based* bisa memonitor trafik jaringan (hanya untuk host tersebut), *system logs*, proses yang berjalan, aktivitas aplikasi, modifikasi dan akses *file*, dan perubahan konfigurasi sistem dan aplikasi. IDS *host-based* biasanya diterapkan pada host yang kritis seperti server yang bisa diakses publik dan server yang berisi informasi yang sensitif.

2.2. Algoritma KNN

Algoritma *k nearest neighbour* adalah salah satu algoritma pembelajaran mesin yang paling sederhana. Algoritma *k nearest neighbour* (k-NN) berdasarkan ide bahwa sebuah objek yang saling berdekatan juga akan memiliki karakteristik yang sama. Jika kita mengetahui karakteristik sebuah objek, maka kita bisa memprediksi tetangga yang paling dekat. K-NN merupakan peningkatan dari *nearest neighbour*, dimana beberapa instance dapat diklasifikasi ke dalam kelas yang sama sebanyak *k neighbour*. Dimana *k* adalah bilangan positif integer.

Untuk mengklasifikasi sebuah kelas baru k-NN mencari *k* tetangga yang paling dekat dan menggunakan kelas mayoritas. Untuk melakukannya, pertama, *k* tetangga yang paling dekat diidentifikasi terlebih dahulu. Untuk mengidentifikasi ini menggunakan *Euclidean distance*. Jarak *Euclidean* dari dua buah instance ($x_1, x_2, x_3, \dots, x_n$) dan ($u_1, u_2, u_3, \dots, u_4$) dirumuskan (Subha & Nambi, 2012):

$$\sqrt{(x_1 - u_1)^2 + (x_2 - u_2)^2 + (x_n - u_n)^2}$$

...Persamaan 1

dimana x_1, x_2, \dots, x_n adalah prediktor untuk instance 1 dan u_1, u_2, \dots, u_n adalah prediktor untuk instance 2.

Algoritma K-nearest neighbor (KNN) merupakan algoritma supervised learning di mana hasil kalsifikasi data baru berdasar kepada kategori mayoritas tetangga terdekat ke-K. Tujuan dari algoritma ini adalah mengklasifikasikan objek baru berdasarkan atribut dan data training. Klasifikasi dilakukan tanpa menggunakan model namun hanya berdasarkan memori. Misalkan diberikan sebuah query, akan didapatkan sejumlah K objek data

training yang terdekat dengan query tersebut.

Klasifikasi dilakukan dengan menggunakan mayoritas suara (seperti dalam pemilu) di antara klasifikasi dari K objek. Algoritma KNN menggunakan klasifikasi ketetenggaan sebagai prediksi terhadap data baru. Algoritma ini bekerja berdasarkan jarak minimum dari data baru terhadap K tetangga terdekat yang telah ditetapkan. Setelah diperoleh K tetangga terdekat, prediksi kelas dari data baru akan ditentukan berdasarkan mayoritas K tetangga terdekat (Kustiyo, 2012).

Algoritma KNN (Alkhatib, Najadat, Hmeidi, & Shatnawi, 2013), (Kustiyo, 2012):

1. Tentukan parameter K = jumlah tetangga terdekat.
2. hitung jarak antara data baru dengan semua *data training*.
3. urutkan jarak tersebut dan tetapkan tetangga terdekat berdasarkan jarak minimum ke-K.
4. periksa kelas dari tetangga terdekat.
5. gunakan mayoritas sederhana dari kelas tetangga terdekat sebagai nilai prediksi data baru.

3. METODE PENELITIAN

Penelitian ini adalah penelitian eksperimen, dimana penelitian melibatkan investigasi hubungan sebab akibat menggunakan tes yang dikendalikan oleh peneliti. Penelitian ini menggunakan *dataset Intrusion detection* yang terdiri dari data training dan data *testing*. Algoritma yang digunakan pada penelitian ini adalah *k-nearest neighbour*. Pertama dataset diterapkan pada algoritma k-NN dengan nilai sebesar 1, kemudian secara berurutan nilai k diubah menjadi 3 dan 5. Software yang digunakan WEKA. Performa algoritma diukur berdasarkan akurasinya. dibandingkan dengan algoritma k-NN dengan nilai k=1 dan 3. Pada confusion

4. PEMBAHASAN

Penelitian ini dilakukan dengan menerapkan algoritma k-NN dalam mendeteksi gangguan jaringan komputer. Dataset pada penelitian ini menggunakan *Intrusion Detection Dataset* yang bisa di *download* dari *website UCI Machine Learning Repository*. Dataset terdiri dari dua bagian yaitu data training dan *data testing*. Label kelas dataset terdiri dari dua kelas yaitu normal dan anomaly. Normal berarti tidak terjadi gangguan pada jaringan komputer, anomaly berarti diduga ada gangguan atau serangan pada jaringan komputer.

Algoritma k-NN mendeteksi sebuah instance baru dengan mengukur jarak antara instance baru dengan *instance* yang sudah ada. Kemudian mengelompokkan instance yang sudah ada sebanyak k *instance*. Selanjutnya menggunakan mayoritas sederhana dipilih kelas *instance* yang memiliki jarak terpendek dengan instance yang baru. Pertama kali dipilih nilai k=1, kemudian secara berturut-turut nilai k diubah menjadi 3 dan 5.

Hasil penelitian menunjukkan bahwa tingkat akurasi algoritma k-NN dengan k=1 sebesar 79,36 %, tingkat akurasi untuk nilai k=3 sebesar 78,59% dan tingkat akurasi untuk nilai k=5 sebesar 78,28%. Hasil selengkapnya bisa dilihat pada tabel 1. Tingkat akurasi terbesar diperoleh ketika nilai k=1, yaitu sebesar 79,36. Semakin besar nilai k, maka tingkat akurasinya semakin menurun. Walaupun penurunannya tidak terlalu signifikan. Dilihat dari waktu yang dibutuhkan membuat model, nilai k=1 memiliki waktu yang paling singkat dibandingkan saat nilai k=3 dan 5.

Jika dilihat dari kurva ROC, algoritma k-NN dengan nilai k=3 memiliki nilai ROC yang terbesar

matrik juga bisa dilihat bahwa jumlah true positif terbesar dimiliki oleh algoritma k-NN dengan nilai k=3.

Tabel 1. Perbandingan performa k-NN dengan perubahan nilai k

Deskripsi	K=1(%)	K=3(%)	K=5(%)
<i>Correctly Classified Instances</i>	79,36	78,59	78,29
<i>Incorrectly Classified Instances</i>	20,64	21,41	21,71
<i>Time taken to build model</i>	0,49 s	1,11 s	4,14 s

Sumber: Dokumentasi Penulis

Tabel 2 . *Confusion Matrix* k-NN dengan nilai k=1

		Predicted	
		Normal	Anomaly
Actual	Normal	9342	369
	Anomaly	4285	8548

Sumber: Dokumentasi Penulis

Tabel 3. *Confusion Matrix* k-NN dengan nilai k=3

		Predicted	
		Normal	Anomaly
Actual	Normal	9345	366
	Anomaly	4461	8372

Sumber: Dokumentasi Penulis

Tabel 3. *Confusion Matrix* k-NN dengan nilai k=5

		Predicted	
		Normal	Anomaly
Actual	Normal	9351	360
	Anomaly	4534	8299

Sumber: Dokumentasi Penulis

5. PENUTUP

Berdasarkan hasil penelitian dapat disimpulkan bahwa algoritma k-NN dengan nilai k=1 memiliki tingkat akurasi terbesar dalam mendeteksi gangguan jaringan komputer. Dari hasil eksperimen diperoleh tingkat akurasi algoritma *k-nearest neighbour* dalam mendeteksi gangguan jaringan komputer sebesar 79,36%. Banyaknya atribut yang digunakan pada penelitian ini membuat waktu yang dibutuhkan dalam melakukan *testing* cukup lama, sehingga penelitian selanjutnya bisa melakukan seleksi atribut yang relevan untuk mendeteksi gangguan jaringan komputer.

DAFTAR PUSTAKA

- Gostev, A., & Namestnikov, Y. (2011, February 17). *Kaspersky Security Bulletin 2010. Statistics, 2010*. Retrieved Juni 6, 2013, from Securelist: http://www.securelist.com/en/analysis/204792162/Kaspersky_Security_Bulletin_2010_Statistics_2010
- Neethu, B. (2012). Classification of Intrusion Detection Dataset Using Machine Learning Approaches. *International Journal of Electronics and Computer Science Engineering*, 1044-1051.

- Olusola, A. A., Oladele, A. S., & Abosede, D. O. (2010). Analysis of KDD '99 Intrusion Detection Dataset for Selection of Relevance Feature . *World Congress on Engineering and Computer Science 2010* . San Fransisco: WCECS 2010.
- Pedrycz, W., & Vukovich, G. (2001). Feature Analysis Through Information Granulation and Fuzzy Sets. (G. V. Witold Pedrycz, Ed.) *Pattern Recognition*, 35, 825-834.
- Scarfone, K., & Mell, P. (Februari, 2007). *Special Publication 800-94: Guide To Intrusion Detection and Prevention Systems* . Gaithersburg, Maryland: National Institute Standard and Technology.
- Tavallae, M., Bagheri, E., Lu, W., & Ghorbani, A. A. (2009). A Detailed Analysis Of The KDD Cup 99 Data Set. *Proceedings Of The 2009 IEEE Symposium On Computational Inteligence in Security and Defense Application (CISDA)* (pp. 53-58). Ottawa: IEEE Press Piscataway, NJ, USA.
- Yu, L., & Huan, L. (2003). Feature Selection for High Dimensional Data: A Fast Correlation-Based Filter Solution. *Proceeding of the Twentieth International Conference on Machine Learning (ICML-2003)*. Washington DC.