

DETEKSI DINI PENYAKIT IUGR (INTRA UTERINE GROWTH RESTRICTION) DENGAN METODE SVM (SUPPORT VECTOR MACHINE)

Irhama Karinasari, Tessy Badriyah

Politeknik Elektronika Negeri Surabaya

Kampus PENS Jl. Raya ITS Sukolilo, Surabaya, 60111

Email: Irhamakarina123@gmail.com

Abstract

IUGR (INTRA UTERINE GROWTH RESTRICTION) is a condition when the baby's growth stops before birth so the baby looks small and does not have normal growth like normal fetal growth patterns. The purpose of this study was to detect the fetus in the womb so as to know the condition of the baby is normal or IUGR by knowing the gestational age, bi-parietal diameter, abdominal circumference, head circumference, fetal length. The purpose of this study was to obtain an accurate prediction of IUGR with "value 0" meaning that IUGR disease was not detected, whereas "value 1" was detected symmetric IUGR disease and "value 2" was Asymmetric IUGR using the SVM method (Support Vector Machine) with 4 kernels. There are 12 parameters of IUGR patients. Patient data were obtained from Jemursari SBY Hospital. In this experiment using the swarm particle optimization (PSO) as an algorithm selection feature. In experiments show that PSO can reduce the attributes of 12 attributes to 4 attributes. In experiments with this multiclass SVM method obtained an accuracy value of 96%.

Keywords: IUGR, SVM

Abstrak

IUGR (INTRA UTERINE GROWTH RESTRICTION) adalah sebuah kondisi ketika pertumbuhan bayi berhenti sebelum dilahirkan sehingga bayi terlihat kecil dan tidak memiliki pertumbuhan yang normal seperti pola pertumbuhan janin yang normal. Tujuan dari penelitian ini adalah untuk mendeteksi janin dalam kandungan agar mengetahui kondisi bayi tersebut normal atau IUGR dengan cara mengetahui usia kehamilan, diameter bi-parietal, lingkar perut, lingkar kepala, panjang fetus. Tujuan penelitian ini adalah untuk memperoleh hasil prediksi yang tepat terhadap penyakit IUGR dengan "nilai 0" artinya tidak terdeteksi penyakit IUGR, sedangkan "nilai 1" adalah terdeteksi penyakit IUGR Simetrik dan "nilai 2" adalah IUGR Asimetrik dengan menggunakan metode SVM (Support Vector Machine) dengan 4 kernel. Terdapat 12 parameter dari pasien IUGR. Data pasien diperoleh dari RS Jemursari SBY. Dalam percobaan ini menggunakan optimasi partikel swarm (PSO) sebagai fitur pilihan algoritma. Dalam eksperimen menunjukkan bahwa PSO dapat mengurangi atribut dari 12 atribut menjadi 4 atribut. Dalam percobaan dengan metode SVM multiclass ini memperoleh nilai akurasi sebesar 96%.

Kata kunci: IUGR, SVM

1. PENDAHULUAN

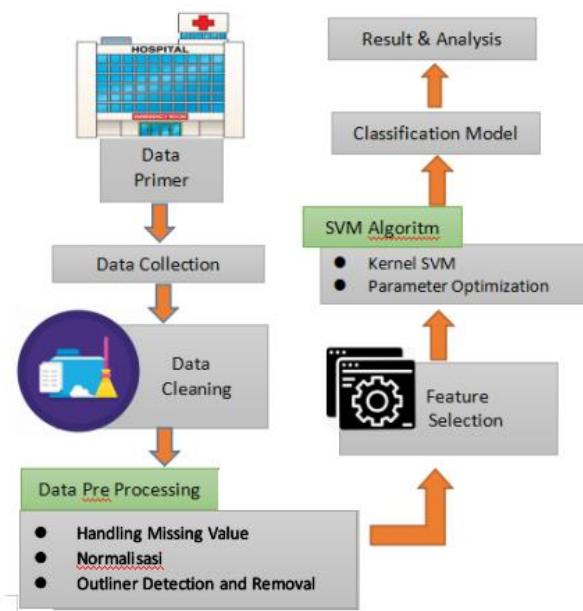
IUGR (Intra Uterine Growth Retriction) adalah sebuah kondisi ketika pertumbuhan bayi berhenti sebelum dilahirkan sehingga bayi terlihat kecil dan tidak memiliki pertumbuhan yang normal seperti pola pertumbuhan janin yang normal. Dalam pemeriksaan dengan USG maka ukuran bayi akan terlihat lebih kecil disertai dengan berat badan bayi yang sangat rendah. Hal itu akan dilihat oleh dokter berdasarkan usia kehamilan yang mengacu pada usia janin yang sebenarnya [1].

Menurut data WHO (*World Health Organization*) AKB (Angka Kematian Bayi) di dunia terus meningkat mencapai 32 per 1000 kelahiran hidup pada tahun 2015 . Sedangkan data SUPAS (Survei Penduduk Antar Sensus) 2015 menyebutkan AKB di Indonesia adalah 22,23 per 1000 kelahiran hidup[2]. Penyebab utama tingginya angka kematian bayi ini, khususnya pada masa perinatal adalah Berat Badan Lahir Rendah (BBLR) [3]. Bayi yang terlahir dengan BBLR berisiko kematian 35 kali lebih tinggi dibandingkan dengan bayi yang berat badan lahirnya diatas 2500 gram. BBLR berkontribusi 60-80% dalam kematian neonatal. Prevalensi global dari BBLR adalah 15,5%, sekitar 20 juta bayi BBLR lahir per tahunnya dan 96,5 % dari mereka berasal dari negara berkembang. Di negara berkembang, BBLR terutama disebabkan oleh hambatan pertumbuhan janin atau Intrauterine Growth Restriction (IUGR) karena kekurangan gizi selama kehamilan. IUGR adalah salah satu penyebab terjadinya kesakitan dan kematian perinatal. Prevalensi kejadian IUGR di negara berkembang 40 % lebih tinggi dari negara maju [4]. IUGR memberikan efek jangka pendek berupa peningkatan resiko kematian janin, neonatus dan bayi, gangguan pertumbuhan setelah lahir, gangguan fungsi kekebalan dan perkembangan intelektual [5].

Adapun beberapa penyebab IUGR antara lain adanya gangguan plasenta, ibu hamil menderita diabetes gestational, ibu hamil menderita tekanan darah tinggi, ibu terkena penyakit infeksi, ibu menderita ginjal, ibu hamil kekurangan nutrisi, ibu hamil sakit anemia, rokok, alkohol, narkoba, kehamilan kembar, ibu hamil terkena preeklamsia, bayi terkena kelainan kromosom, penggunaan obat antikonvulsan, pernah melahirkan bayi IUGR, dan gangguan genetik dari orang tua [6,7].

2. METODOLOGI PENELITIAN

Dalam menangani pembuatan model klasifikasi kategori IUGR, maka dibutuhkan sebuah sistem desain sebagai gambaran tahapan untuk menyelesaikan masalah tersebut. Berikut Gambar 1 menunjukkan desain sistem secara umum pada penelitian ini.



Gambar 1. Desain Sistem Secara Umum Untuk Klasifikasi IUGR

2.1. Data Collection

Data collection merupakan proses pengumpulan data pasien dari Rumah Sakit atau informasi yang diperlukan sebagai dataset dalam penelitian ini.

2.2. Pembersihan Data (Data Cleaning)

Pembersihan data merupakan proses menghilangkan noise dan data yang tidak relevan. Pada umumnya data yang diperoleh, baik dari database memiliki isian isian yang tidak sempurna seperti data yang hilang, data yang tidak valid atau juga hanya sekedar salah ketik. Data data yang tidak relevan itu juga lebih baik dibuang. Pembersihan data juga akan mempengaruhi performasi dari teknik data mining karena data yang ditangani akan berkurang jumlah dan kompleksitasnya [8].

2.3. Data Pre-Processing

Tujuannya preprosesing dalam data mining adalah menstrasformasi data ke suatu format yang prosesnya lebih mudah dan efektif untuk kebutuhan pemakai yaitu mendapatkan hasil akurat, pengurangan waktu komputasi untuk *large scale problem*, membuat nilai data menjadi lebih kecil tanpa merubah informasi yang dikandungnya. *Preprocessing* mengambil porsi 60% dalam tahap-tahap pemrosesan data mining [8]. yang terdiri dari *handling missing value*, *normalisasi*, *handling missing value*.

2.4. Feature Selection

Particle swarm optimization (PSO) adalah salah satu alat langka yang secara comis mudah dikodekan dan diimplementasikan sembari menghasilkan hasil yang sangat bagus. Memulai algoritma PSO, kecepatan awal (*velocity*) dan posisi awal (*position*) ditentukan secara random [9].

2.5. SVM Algoritm

Support vector machines (SVM) adalah salah satu metode diskriminatif yang paling tepat untuk digunakan dalam klasifikasi. Metode ini bekerja berdasarkan pada Structural Risk Minimization, yang bertujuan untuk menemukan hyperplane terbaik yang memisahkan dua buah class pada input space [10]. SVM juga banyak digunakan untuk melakukan klasifikasi otomatis. Beberapa penelitian telah menggunakan SVM untuk berbagai penerapan, diantaranya adalah pada pengenalan citra, analisis medik, ataupun untuk melakukan prediksi [11].

Tabel 1. kernel yang umum digunakan

Jenis Kernel	Definisi
Polynomial	$K(\vec{x}_i, \vec{x}_j) = (\vec{x}_i \cdot \vec{x}_j + 1)^p$
Gaussian RBF	$K(\vec{x}_i, \vec{x}_j) = \exp\left(-\frac{\ \vec{x}_i - \vec{x}_j\ ^2}{2\sigma^2}\right)$
Sigmoid	$K(\vec{x}_i, \vec{x}_j) = \tanh(\alpha \vec{x}_i \cdot \vec{x}_j + \beta)$
Linear	$K(\vec{x}_i, \vec{x}_j) = \vec{x}_i' \vec{x}_j$

2.6. Kernel Kernel SVM

2.6.1. Polynominal

Poyinomial kernel merupakan fungsi kernel yang digunakan ketika data tidak terpisah secara linear. Polinomial kernel sangat cocok untuk permasalahan dimana semua training dataset dinormalisasi [14].

2.6.2. Radial Base Function (RBF)

RBF kernel merupakan fungsi kernel yang biasa digunakan dalam analisis ketika data tidak terpisah secara linear. RBF kernel memiliki dua parameter yaitu Gamma dan Cost. Parameter Cost atau biasa disebut sebagai C merupakan parameter yang bekerja sebagai pengoptimalan SVM untuk menghindari misklasifikasi di setiap sampel dalam training dataset. Parameter Gamma menentukan seberapa jauh pengaruh dari satu sampel training dataset dengan nilai rendah berarti "jauh", dan nilai tinggi berarti "dekat". Dengan gamma yang rendah, titik yang berada jauh dari garis pemisah yang masuk akal dipertimbangkan dalam perhitungan untuk garis pemisah. Ketika gamma tinggi berarti titik – titik berada di sekitar garis yang masuk akal akan dipertimbangkan dalam perhitungan.

2.6.3. Sigmoid Kernel

Kernel Sigmoid berasal dari bidang Jaringan Saraf Tiruan, di mana fungsi sigmoid bipolar sering digunakan sebagai fungsi aktivasi untuk neuron buatan. Sangat menarik untuk dicatat bahwa model SVM yang menggunakan fungsi kernel sigmoid setara dengan jaringan saraf perceptron dua lapis. Kernel ini cukup populer untuk mendukung mesin vektor karena asalnya dari teori jaringan saraf. Juga, meskipun hanya pasti bersyarat positif, telah terbukti berkinerja baik dalam praktik. Ada dua parameter yang dapat disesuaikan di kernel sigmoid, alpha slope dan intercept constant c. Nilai umum untuk alpha adalah $1 / N$, di mana N adalah dimensi data.

2.6.4. Linear Kernel

Linear kernel merupakan fungsi kernel yang paling sederhana. Linear kernel digunakan ketika data yang dianalisis sudah terpisah secara linear. Linear kernel cocok ketika terdapat banyak fitur dikarenakan pemetaan ke ruang dimensi yang lebih tinggi tidak benar – benar meningkatkan kinerja seperti pada klasifikasi teks.

2.7. SVM Multiclass

SVM Multiclass pada dasarnya terdiri dari modul pembelajaran dan modul klasifikasi, di mana model klasifikasi diterapkan pada data baru. Ini dapat diimplementasikan dengan mengubah SVM kelas tunggal menjadi kelipatan klasifikasi biner yang dapat dilakukan dengan membedakan pengklasifikasi berdasarkan label tertentu [15].

2.8. SVM dengan normalisasi

Normalisasi dalam kegiatan data mining merupakan proses penskalaan nilai atribut dari data sehingga bisa jatuh pada range tersebut [9].

2.8.1. SVM dengan normalisasi min-max

Metode min-max merupakan metode normalisasi dengan melakukan transformasi linier terhadap data asli.

Rumus:

$$\text{Newdata} = (\text{data-min}) * (\text{newmax-newmin}) / (\text{max-min}) + \text{newmin}$$

Newdata	= Data hasil normalisasi
Min	= Nilai minimal dari data per kolom
Max	= Nilai maximal dari data per kolom
Newmin	= batas minimal yang kita berikan
Newmax	= batas maximal yang kita berikan

2.8.2. SVM dengan normalisasi z-score

Metode Z-score merupakan metode normalisasi yang berdasarkan mean (nilai rata-rata) dan standard deviation (deviasi standar) dari data.

Rumus:

$$\text{Newdata} = (\text{data} - \text{mean}) / \text{std}$$

Newdata = Data hasil normalisasi
Mean = Nilai rata-rata dari data per kolom
Std = Nilai dari standard deviasi

2.9. Analisa Performa

Dataset berjumlah 154 data dengan 3 kelas yaitu: tidak IUGR, IUGR Simetrik dan IUGR Asimetrik. Analisa performa dilakukan berdasarkan *Accuracy*, *Precision*, *Recall*, *F1 – Measure*, *ROC*, *Parameter Optimization*, *Neural Network*.

3.HASIL DAN PEMBAHASAN

3.1. Karakteristik dan Data Penelitian

Berikut ini tabel gambaran data IUGR yang terdiri dari atribut, kelas dan nilai binary dan numeric yang akan digunakan dalam penelitian yang ditunjukkan pada tabel dibawah:

Tabel 2. Gambaran data IUGR yang terdiri dari atribut, kelas dan nilai binary dan numeric

No	Atribut	Nilai Data	Tipe Data
1.	Umur Ibu Hamil	Sesuai umur ibu hamil	Numerik
2.	BMI (Body mass index)	Sesuai tinggi badan dan berat badan ibu hamil	Numerik
3.	Class BMI	{'Underweight'=1, 'Normal' = 2, 'Overweight' = 3, 'Class I Obesity' = 4, 'Class II Obesity' = 5, 'Class III Obesity' = 6}	Kategorikal
4.	Kenaikan berat badan ibu hamil	Sesuai kenaikan berat badan ibu hamil	Numerik
5.	Penyakit Ibu Hamil	Sesuai penyakit ibu hamil	Numerik
6.	Riwayat Penyakit Keluarga Ibu Hamil	Sesuai riwayat penyakit ibu hamil	Numerik
7.	Lingkar Lengan Atas (LILA)	Sesuai LILA ibu hamil	Numerik
8.	Tekanan Darah	Sesuai tekanan darah ibu hamil	Numerik
9.	Nadi	Sesuai nadi ibu hamil	Numerik
10.	TFU (Tinggi Fundus Uteri)	Sesuai TFU ibu hamil	Numerik
11.	Usia Kehamilan	Sesuai Usia kehamilan ibu hamil	Numerik
12.	Class	{tidak IUGR = 0, IUGR simetrik=1,IUGR Asimetrik =2}	Binary

3.2. Hasil Experiment

3.2.1. Fitur Seleksi

Seleksi fitur ini menggunakan WEKA untuk mengurangi atribut pada IUGR yang bertujuan untuk meningkatkan akurasi pada hasil klasifikasi IUGR. Dengan menggunakan metode PSO dan telah memasukkan 12 atribut tersebut dan hasilnya telah dijadikan proses learning untuk membandingkan apakah hasil akurasinya bertambah jika atributnya berkurang. Implementasi penelitian ini dengan menggunakan PSO.

Tabel 3. Hasil Sebelum dan Sesudah Proses Seleksi Fitur

	Atribut	Jumlah Atribut	Hasil Akurasi
Sebelum dilakukan seleksi fitur	1. Umur ibu hamil 2. Tinggi badan ibu hamil, 3. Berat badan ibu hamil, 4. Body mass index, 5. Kelebihan berat badan ibu hamil, 6. Penyakit Ibu hamil, Riwayat penyakit keluarga, 7. Lingkar lengan, 8. Tekanan darah, 9. Nadi, 10. TFU, 11. Usia kehamilan (minggu), 12. Class	12	82,61 %
Setelah dilakukan seleksi fitur	1.Tekanan darah, 2.Kenaikan berat badan, 3.Penyakit Ibu, 4.TFU	4	93,48 %

Tabel 4. Akurasi Hasil Perbandingan Metode NN dan SVM

	Jumlah Atribut	Neural Network	SVM
Sebelum dilakukan seleksi fitur	11	85,98%	82,61 %
Setelah dilakukan seleksi fitur	4	96,28 %	93,48 %

3.2.2. Percobaan IUGR dengan normalisai Min max dan Z-score

```
In [3]: runfile('E:/TESIS/Python/svmMulticlass1.py',
              wdir='E:/TESIS/Python')
iter 1 violation 1.0
iter 2 violation 0.1168373685446267
iter 3 violation 0.05746541608707462
iter 4 violation 0.03437553546420906
Result:
0.8627450980392157
```

Gambar 16. Hasil Akurasi data IUGR dengan normalisasi Min max

```
iter 1 violation 1.0
iter 2 violation 0.6091447461384655
iter 3 violation 0.26653941469148873
iter 4 violation 0.16099164756699502
iter 5 violation 0.14160639484229365
iter 6 violation 0.10965829908028384
iter 7 violation 0.08795060657438299
iter 8 violation 0.06705843884894386
iter 9 violation 0.04826226702920012
Result:
0.7843137254901961
```

Gambar 17. Hasil Akurasi data IUGR dengan normalisasi Z-Score

Percobaan di atas menggunakan normalisasi min max dan z-score dengan C=0.1, tol=0.05, max_iter=100 diperoleh akurasi Min max sebesar 86 % dan z-score sebesar 78%. Dengan demikian dapat disimpulkan bahwa normalisasi min max lebih unggul dari z-score.

3.2.3 Percobaan SVM Multiclass dengan 4 kernel

3.2.3.1 SVM Multiclass dengan linear kernel

```
In [5]: runfile('E:/TESIS/Python/svm4kernel3.py', wdir='E:/TESIS/Python')
[[27  0  1]
 [ 1  0  0]
 [ 2  0  0]]
      precision    recall   f1-score   support
          0       0.90      0.96      0.93       28
          1       0.00      0.00      0.00        1
          2       0.00      0.00      0.00        2
  micro avg       0.87      0.87      0.87       31
  macro avg       0.30      0.32      0.31       31
 weighted avg     0.81      0.87      0.84       31
```

Gambar 18. Hasil Akurasi SVM Multiclass dengan linear kernel

3.2.3.2. SVM Multiclass dengan Polynomial kernel

```
In [6]: runfile('E:/TESIS/Python/svm4kernel3.py', wdir='E:/TESIS/Python')
[[24  1  1]
 [ 1  0  0]
 [ 3  1  0]]
      precision    recall   f1-score   support
          0       0.86     0.92     0.89      26
          1       0.00     0.00     0.00       1
          2       0.00     0.00     0.00       4

   micro avg       0.77     0.77     0.77      31
   macro avg       0.29     0.31     0.30      31
weighted avg       0.72     0.77     0.75      31
```

Gambar 19. Hasil Akurasi SVM Multiclass dengan Polynomial kernel

3.2.3.3. SVM Multiclass dengan Gaussian kernel

```
In [7]: runfile('E:/TESIS/Python/svm4kernel3.py', wdir='E:/TESIS/Python')
[[26  0  1]
 [ 1  0  0]
 [ 1  2  0]]
      precision    recall   f1-score   support
          0       0.93     0.96     0.95      27
          1       0.00     0.00     0.00       1
          2       0.00     0.00     0.00       3

   micro avg       0.84     0.84     0.84      31
   macro avg       0.31     0.32     0.32      31
weighted avg       0.81     0.84     0.82      31
```

Gambar 20. Hasil Akurasi SVM Multiclass dengan Gaussian kernel

3.2.3.4. SVM Multiclass dengan Sigmoid kernel

```
In [8]: runfile('E:/TESIS/Python/svm4kernel3.py', wdir='E:/TESIS/Python')
[[25  1  1]
 [ 0  0  1]
 [ 2  0  1]]
      precision    recall   f1-score   support
          0       0.93     0.93     0.93      27
          1       0.00     0.00     0.00       1
          2       0.33     0.33     0.33       3

   micro avg       0.84     0.84     0.84      31
   macro avg       0.42     0.42     0.42      31
weighted avg       0.84     0.84     0.84      31
```

Gambar 21. Hasil Akurasi SVM Multiclass dengan Sigmoid kernel

Tabel 5. Perbandingan SVM Multiclass dengan 4 kernel

SVM Multiclass	Precision	Recall	F1-score
Linear	90%	96%	93%
Polynomial	86%	92%	89%
Gaussian	93%	96%	95%
Sigmoid	93%	93%	93%

4. SIMPULAN

IUGR (Intra Uterine Growth Retriction) adalah sebuah kondisi ketika pertumbuhan bayi berhenti sebelum dilahirkan sehingga bayi terlihat kecil dan tidak memiliki pertumbuhan yang normal seperti pola pertumbuhan janin yang normal. Dalam pemeriksaan dengan USG maka ukuran bayi akan terlihat lebih kecil disertai dengan berat badan bayi yang sangat rendah. Oleh karena itu diperlukan penanganan yang cepat agar bayi dapat lahir dengan normal.

Dalam melakukan percobaan dengan menggunakan metode SVM Multiclass dengan 4 kernel dan menghasilkan nilai akurasi 96% Semoga dengan adanya percobaan ini dapat menolong pihak Rumah Sakit dalam menangani Ibu hamil dengan bayi dalam kondisi IUGR.

DAFTAR PUSTAKA

- [1] Suhag A, Berghella V, "Intrauterine growth restriction (IUGR): etiology and diagnosis", Current Obstetrics and Gynecology Reports. 2013;2(2):102–111.
- [2] Lausman A, McCarthy FP, Walker M, Kingdom J. "Screening, diagnosis, and management of intrauterine growth restriction", Journal of Obstetrics and Gynaecology Canada. 2012;34(1):17–28.
- [3] Penyusun T. "Laporan Pencapaian Tujuan Pembangunan Milenium di Indonesia 2011", Kementerian Perencanaan Pembangunan Nasional/Badan Perencanaan Pembangunan Nasional. 2012;
- [4] Departemen Kesehatan. "Upaya Percepatan Penurunan Angka Kematian Ibu", [Internet]. 2018 [cited 2018 Nov 8]. Available from: http://www.kesehatanibu.depkes.go.id/wpcontent/uploads/downloads/2013/01/Factsheet_Upaya-PP-AKI.pdf
- [5] King Edward Memorial Hospital. "Clinical guidelines obstetrics and midwifery", Complication of pregnancy intrauterine growth restriction. 2013.
- [6] Cunningham FG. Obstetri Williams: "Adaptasi Ibu Terhadap Kehamilan". 21st ed. Jakarta: EGC; 2005.
- [7] Prawirohardjo S. "Ilmu Kebidanan", Jakarta: Yayasan Bina Pustaka Sarwono Prawirohardjo; 2008.
- [8] Gunawan D. "Evaluasi Performa Pemecahan Database dengan Metode Klasifikasi Pada Data Preprocessing Data mining", Khazanah Informatika: Jurnal Ilmu Komputer dan Informatika. 2016;2(1):10–13.
- [9] Junaedi H, Budianto H, Maryati I, Melani Y. "Data transformation pada data mining", Prosiding Konferensi Nasional Inovasi dalam Desain dan Teknologi-IDeaTech. 2011;93–99.
- [10] Gadagkar AV, Shreedhara KS. "Features based IUGR diagnosis using variational level set method and classification using artificial neural networks". In: 2014 Fifth International Conference on Signal and Image Processing. IEEE; 2014. p. 303–309.

- [11] Auria L, Moro RA. “**Support vector machines (SVM) as a technique for solvency analysis**”. 2008;
- [12] Bergstra J, Bengio Y. “**Random search for hyper-parameter optimization**. *Journal of machine learning research*”. 2012;13(Feb):281–305.
- [13] Bagi KS, Shreedhara KS. “**Biometric measurement and classification of IUGR using neural networks**”. In: 2014 International Conference on Contemporary Computing and Informatics (IC3I). IEEE; 2014. p. 157–161.
- [14] Crowley JL. “**Intelligent Systems: Reasoning and Recognition [Internet]**”, 2016 [cited 2019 Jan 15]. Available from: <http://www-prima.imag.fr/jlc/Courses/2015/ENSI2.SIRR/ENSI2.SIRR.S5.pdf>
- [15] Levine S. Week 7 “**Multiclass Support Vector Machines [Internet]**”. 2019 [cited 2020 Jan 15]. Available from: https://courses.cs.washington.edu/courses/cse446/16sp/svm_3.pdf