



Aidah Fidayanti_221020700087_Revisi Semhas

18%
Suspicious
texts



- 4% Similarities
 - 1 % similarities between quotation marks
 - 0 % among the sources mentioned
- 12% Unrecognized languages
- 4% Texts potentially generated by AI

Document name: Aidah Fidayanti_221020700087_Revisi Semhas.docx
Document ID: 8a48c45373babbc9da8653deb6ed66daeafc765c
Original document size: 6.02 MB

Submitter: UMSIDA Perpustakaan
Submission date: 2/19/2026
Upload type: interface
analysis end date: 2/19/2026




Number of words: 5,358
Number of characters: 38,276

Location of similarities in the document:





Sources of similarities

Main sources detected

No.	Description	Similarities	Locations	Additional information
1	 Artikel PSPI_Acopen_Submit.docx Artikel PSPI_Acopen_Submit #55f10c Comes from my group 16 similar sources	2%		 Identical words: 2% (85 words)
2	 archive.umsida.ac.id https://archive.umsida.ac.id/index.php/archive/preprint/download/8248/59291/65785 16 similar sources	1%		 Identical words: 1% (78 words)
3	 doi.org Implementasi Support Vector Machine dan Resampling dalam Analisis U... https://doi.org/10.31603/komtika.v9i2.14813 1 similar source	< 1%		 Identical words: < 1% (44 words)
4	 doi.org PERBANDINGAN TEKNIK OPTIMASI GRID SEARCH DAN RANDOMIZED SE... https://doi.org/10.36080/skanika.v8i1.3328 1 similar source	< 1%		 Identical words: < 1% (25 words)

Sources with incidental similarities

No.	Description	Similarities	Locations	Additional information
1	 ojs.udb.ac.id https://ojs.udb.ac.id/Senatib/article/view/5299	< 1%		 Identical words: < 1% (39 words)
2	 archive.umsida.ac.id Analysis Operational Reliability Of Concrete Pump Using F... https://archive.umsida.ac.id/index.php/archive/preprint/download/9485/68360	< 1%		 Identical words: < 1% (20 words)
3	 www.medgen-journal.ru The results of the use of molecular genetic technolog... https://www.medgen-journal.ru/jour/article/download/1380/1022	< 1%		 Identical words: < 1% (24 words)
4	 hdl.handle.net Not All Attributions Are Self-Serving: A Preference for Agency ov... https://hdl.handle.net/11565/4071104	< 1%		 Identical words: < 1% (20 words)
5	 dx.doi.org http://dx.doi.org/10.34128/jjsi.v9i1	< 1%		 Identical words: < 1% (12 words)

Points of interest

Predictive Maintenance on Paving Machine Using Support Vector Machine (SVM)
[Predictive Maintenance Pada Mesin Paving Menggunakan Support Vector Machine (SVM)]

Aidah Fidayanti1),



Tedjo Sukmono *,2)

archive.umsida.ac.id
<https://archive.umsida.ac.id/index.php/archive/preprint/download/8248/59291/65785>

1)Program
Studi Teknik Industri,
Universitas Muhammadiyah Sidoarjo,
Indonesia
2)

Artikel PSPI_Acopen_Submit.docx | Artikel PSPI_Acopen_Submit
Comes from my group

Program Studi Teknik Industri,
Universitas
Muhammadiyah Sidoarjo, Indonesia

*Email
Penulis
Korespondensi:
thedjoss@umsida.ac.id2)

Abstract.

Predictive maintenance is a strategy that uses machine operational data to predict potential damage before it occurs, thereby reducing downtime and maintaining the availability of production equipment. In 2024, PT XYZ experienced 342.75 hours of downtime with 82.30% availability and an output of 3,950,661 units, requiring more structured maintenance planning to minimize disruptions. This study aims to utilize predictions of the downtime duration of a paving machine's hydraulic system to develop a more efficient preventive maintenance schedule. The methods used were linear Support Vector Machine (SVM) and Multinomial Naive Bayes to predict downtime duration, with SVM achieving an accuracy of 89,1% with an MSE of 0,109 and Multinomial Naive Bayes achieving 85,5% with 0,145.



Keywords – Predictive maintenance, Support Vector Machine (SVM), Naive Bayes, Paving machine

Abstrak. Pemeliharaan prediktif adalah strategi yang menggunakan data operasional mesin untuk memperkirakan potensi kerusakan sebelum terjadi, sehingga dapat mengurangi downtime dan menjaga ketersediaan peralatan produksi. Pada tahun 2024, PT XYZ mengalami downtime 342,75 jam dengan ketersediaan 82,30% dan output 3.950.661 unit, sehingga dibutuhkan perencanaan pemeliharaan yang lebih terstruktur untuk meminimalkan gangguan.

Penelitian ini bertujuan memprediksi durasi downtime sistem hidrolik mesin paving untuk menyusun jadwal perawatan preventif yang lebih efisien. Metode yang digunakan adalah Support Vector Machine (SVM) linear dan Multinomial Naive Bayes untuk memprediksi durasi downtime, dengan hasil akurasi SVM mencapai 89,1% dengan MSE 0,109 dan Multinomial Naive Bayes 85,5% dengan 0,145.

Kata Kunci – Predictive maintenance, Support Vector Machine (SVM), Naive Bayes, Mesin paving

I. Pendahuluan

PT XYZ merupakan perusahaan yang bergerak di industri konstruksi beton, khususnya dalam produksi paving berbahan beton masonry. Peningkatan kapasitas produksi mesin paving untuk memenuhi permintaan pasar tidak didukung oleh keandalan mesin yang menyebabkan berbagai masalah operasional. Salah satu cabang perusahaan ini hanya memiliki satu batching plant yang sering mengalami downtime akibat peningkatan permintaan, kurangnya keterampilan teknisi, terbatasnya suku cadang, dan proses pengadaan yang lambat karena harus mendapatkan persetujuan dari kantor pusat. Selain itu, belum adanya sistem penjadwalan pemeliharaan yang terstruktur dan berbasis data historis semakin memperburuk keadaan, sehingga perawatan yang dilakukan cenderung bersifat reaktif. Penjadwalan pemeliharaan yang efektif sangat penting untuk mencegah kerusakan mesin, meningkatkan waktu operasional, dan efisiensi produksi [1].

Permasalahan yang dihadapi perusahaan ini adalah kerusakan sistem hidrolik pada mesin wet mixing paving yang menyebabkan downtime dan gangguan dalam proses produksi. Jumlah jam kerja yang tersedia adalah 8 jam per hari, sedangkan downtime tertinggi pada tahun 2024 mencapai 342,75 jam sehingga availability mencapai 82,30% dan menghasilkan produksi sebanyak 3.950.661 unit. Oleh karena itu, diperlukan pendekatan pemeliharaan prediktif untuk mendeteksi kerusakan sejak dini dan memperkirakan waktu kegagalan mesin untuk menjaga kelancaran operasional [2]. Metode Support Vector Machine (SVM) dipilih sebagai solusi untuk membangun model pemeliharaan prediktif yang dapat memprediksi kerusakan pada sistem hidrolik sehingga dapat mengurangi downtime dan meningkatkan efisiensi produksi mesin wet mixing paving [3].

Support Vector Machine (SVM) adalah algoritma dalam pembelajaran terawasi (supervised learning) yang dikenal memiliki kinerja unggul dibandingkan dengan algoritma lainnya sehingga sering digunakan di berbagai penelitian [4]. Penerapan SVM dalam industri bertujuan mengurangi waktu henti, meningkatkan efisiensi biaya operasional, dan mengoptimalkan jadwal perawatan, sehingga menjadikannya pilihan andal untuk sistem pemeliharaan berbasis data [5]. Pada penelitian ini menerapkan SVM dengan hyperplane linear untuk secara efisien memisahkan dua kelas data dalam ruang fitur berdimensi tinggi [6].

SVM efektif dalam mengolah data berdimensi tinggi dan menghasilkan hasil yang akurat. Di sisi lain, Naive Bayes lebih sederhana dan cepat dalam proses klasifikasi [7]. Naive Bayes adalah algoritma dalam data mining dan machine learning yang berlandaskan pada teorema Bayes [8]. Penelitian ini menggunakan Multinomial Naive Bayes sebagai model perbandingan karena algoritma tersebut efektif dalam klasifikasi teks berdasarkan frekuensi kata. Algoritma ini mengasumsikan independensi antar fitur dan menghitung probabilitas kata pada setiap kelas sentimen sesuai dengan pendekatan TF-IDF [9].

Penelitian sebelumnya telah mengembangkan sistem pemeliharaan prediktif untuk batching plant dengan menggunakan Support Vector Machine (SVM) untuk memprediksi waktu kerusakan mesin [10]. Penelitian lain menerapkan pemeliharaan prediktif pada lini mesin produksi Dry 8 dengan SVM yang menggunakan kernel linear untuk meramalkan kegagalan mesin [11]. Perbandingan antara SVM dan Naive Bayes dalam pemeliharaan prediktif mesin industri menggunakan data sensor menunjukkan validitas pendekatan klasifikasi downtime [12]. Temuan penelitian mengindikasikan bahwa Naive Bayes lebih cepat untuk pemantauan real-time, sedangkan SVM lebih akurat dalam klasifikasi downtime [13]. Selain itu, evaluasi dan perbandingan SVM dengan Naive Bayes sebagai model pembelajaran mesin digunakan untuk memprediksi dan mengurangi downtime mesin melalui pemeliharaan prediktif pada dataset sensor industri [14].

Penelitian ini berbeda dari lima penelitian sebelumnya karena menggunakan jenis dataset dan peralatan manufaktur yang berbeda. Dalam penelitian ini, data durasi downtime pada sistem hidrolik mesin paving diklasifikasikan secara multiclass bukan binary. Tujuan penelitian ini adalah untuk memprediksi kategori durasi downtime sistem hidrolik mesin paving sebagai dasar dalam menyusun jadwal perawatan preventif yang lebih terstruktur, sehingga dapat mengendalikan downtime dan meminimalkan penurunan output produksi.

II. Metode

Penelitian ini dilaksanakan di PT XYZ di Sumpoko, Kecamatan Gempol, Kabupaten Pasuruan, Jawa Timur selama enam bulan dari September 2025 hingga Februari 2026. Metode yang diterapkan terdiri dari observasi, wawancara, dan pengumpulan data historis mengenai pemeliharaan dan produksi mesin paving. Data tersebut dianalisis menggunakan metode Support Vector Machine (SVM) untuk mengklasifikasi durasi downtime mesin berdasarkan aktivitas pemeliharaan dan kondisi produksi. Selain itu, Naive Bayes digunakan sebagai model perbandingan dalam analisis downtime yang berbasis teks aktivitas pemeliharaan. Kedua metode ini dipilih untuk memberikan pemahaman yang lebih baik mengenai pola downtime mesin paving sehingga dapat dirumuskan rekomendasi pemeliharaan yang lebih akurat. Proses penelitian dijelaskan secara sistematis dalam diagram alir yang ditampilkan dalam gambar 1, mulai dari identifikasi masalah hingga penarikan kesimpulan.

Gambar 1. Diagram Alir Penelitian

Pada gambar 1 menunjukkan diagram alir penelitian yang dijelaskan secara rinci sebagai berikut:

Field Study and Literature Review

Field study atau studi lapangan dilakukan melalui observasi langsung pada saat pelaksanaan kegiatan produksi dan pemeliharaan mesin paving di salah satu cabang PT XYZ, yaitu di Pandaan.



Observasi dilakukan dengan mengamati proses produksi paving, perawatan mesin, kondisi terbatasnya stok spare part di gudang,

dan pencatatan data downtime dalam sistem Enterprise Resource Planning (ERP). Literature review atau studi literatur dilakukan dengan menganalisis metode yang akan diterapkan berdasarkan artikel,jurnal, buku, dan karya ilmiah lainnya yang relevan dengan topik penelitian yang sedang dibahas.

Identification of Problems

Identifications of problems atau identifikasi masalah dilakukan setelah studi literatur dan lapangan, diikuti dengan perumusan masalah berdasarkan hasil observasi.

Data Collection

Data collection atau pengumpulan data pada



Document from another user

Comes from another group

penelitian ini menggunakan data primer dan data sekunder. Data primer

diperoleh dari wawancara kepala produksi, kepala divisi pemeliharaan, dan seorang manajer untuk mengidentifikasi penyebab downtime pada mesin wet mixing paving dan informasi untuk pengelolaan pemeliharaan. Data sekunder diambil dari database perusahaan yang terdiri dari data historis downtime, catatan aktivitas pemeliharaan sistem hidrolik, dan data produksi paving dari Oktober 2022 hingga Oktober 2025. Data historis selama tiga tahun mengenai downtime sistem hidrolik dan produksi paving mendukung keberhasilan dalam pemodelan prediktif serta klasifikasi durasi downtime [15]. Data yang dikumpulkan mencakup 550 informasi mengenai downtime dan terdiri dari berbagai atribut yang dijelaskan dalam tabel 1.

Tabel 1. Attribute Dataset

No Attribute Description Type Data

1 Tanggal Penanda tanggal pencatatan aktivitas pemeliharaan dan produksi Object

2 Jenis Jenis aktivitas pemeliharaan seperti preventif atau kuratif Object

3 Aktivitas Detail aktivitas pemeliharaan seperti servis, perbaikan, atau cek rutin Object

4 Komponen Komponen mesin yang mengalami perawatan atau perbaikan Object

5 Durasi Downtime (Jam) Lama waktu mesin berhenti beroperasi akibat pemeliharaan Numeric

6 Kategori Downtime Kategori lama downtime seperti singkat, sedang, lama Object

7 Total Produksi Jumlah hasil produksi paving per hari Numeric

8 Jenis Kode Kode numerik hasil pengubahan atribut jenis ke bentuk kategori numerik Numeric

9 Rasio Downtime Produksi Perbandingan durasi downtime terhadap total produksi pada hari yang sama Numeric

Preprocessing Data

Preprocessing data adalah tahap persiapan data sebelum analisis yang mencakup pembersihan,



transformasi, dan pengintegrasian data [16].

Dalam penelitian ini, tahap preprocessing data terdiri dari empat langkah utama,



yaitu data cleaning (pembersihan data), text processing (pengolahan teks), labeling (pelabelan 3 kelas), dan feature engineering (rekayasa fitur).

Feature Extraction

Feature extraction adalah proses konversi kata menjadi angka dalam bentuk vektor dilakukan karena komputer hanya dapat mengenali dan memproses angka, selama angka tersebut masih memiliki makna yang sesuai dengan kata tersebut [17]. Pada penelitian ini, feature extraction terdiri dari dua langkah,



yaitu TF-IDF (text) dan numerical features.

Split Data

Split data adalah teknik untuk memisahkan dataset dan memengaruhi performa model klasifikasi dalam algoritma pembelajaran mesin [18]. Dalam penelitian ini menggunakan metode pembagian data tipe stratified split sehingga menghasilkan data training dan data testing.

Classification Models

Model klasifikasi ini mencakup SVM dengan kernel linier, serta data teks dan angka. Sementara itu, Naive Bayes terdiri dari model multinomial dengan parameter default dan hanya menggunakan data teks.

Prediction

Pada tahap prediksi ini akan mengklasifikasikan kategori downtime sistem hidrolik ke dalam tiga kategori, yaitu singkat (< 1 jam), sedang (1-3 jam), dan lama (> 3 jam) dengan

menggunakan model SVM dan Naive Bayes pada data uji.

Evaluation

Pada tahap evaluasi, model dinilai dengan confusion matrix dan MSE. Confusion matrix adalah matriks untuk menunjukkan hasil klasifikasi dan mengevaluasi kinerja model klasifikasi dengan menggunakan metrik seperti akurasi, presisi, recall, dan F1-score [19]. Adapun rumus confusion matrix yang digunakan dalam penelitian ini adalah sebagai berikut.



Accuracy= (1)

Precision= (2)

Recall= (3)

F1-Score= $2 \times$ (4)

Sumber:

[20]

Keterangan:

TPP (True Positive Positive)= Data positif yang diprediksi benar sebagai positif

TNTNt (True Neutral Neutral)= Data netral yang diprediksi benar sebagai netral

NtFP (Neutral False Positive)= Data netral yang terklasifikasi sebagai positif

NFP (Negative False Positive)= Data negatif yang terklasifikasi sebagai positif

PFNt (Postive False Neutral)= Data positif yang terklasifikasi sebagai netral

PFN (Positive False Negative)= Data positif yang terklasifikasi sebagai negatif

Langkah berikutnya adalah menghitung nilai Mean Squared Error (MSE) untuk mengukur tingkat kesalahan prediksi model. MSE merupakan metrik yang



github.com | GitHub - zefanyadita/Predicting-Machine-Failure-Type-ML-Project-

<https://github.com/zefanyadita/Predicting-Machine-Failure-Type-ML-Project->

menghitung rata-rata dari selisih kuadrat antara nilai prediksi dan nilai aktual

[21]. MSE dipilih sebagai metrik utama karena nilai yang lebih rendah merepresentasikan kinerja yang lebih baik. Sebuah nilai MSE sebesar 0 menunjukkan model yang sempurna, sedangkan nilai terkecil dari MSE menggambarkan kinerja terbaik, semakin mendekati nol, semakin baik kinerja model tersebut [22][23]. Rumus MSE adalah sebagai berikut.

MSE= (5)

Sumber: [24]

Keterangan:

n= Jumlah keseluruhan data

= Nilai aktual pada data ke-i

= Nilai hasil prediksi pada data ke-i

Model Comparison

Model perbandingan ini menganalisis kinerja LinearSVC pada SVM dan Multinomial Naive Bayes dalam klasifikasi downtime. Analisis dilakukan dengan menggunakan metrik accuracy, precision, recall, F1-score, dan MSE, serta menyajikan visualisasi grafik batang untuk membandingkan kinerja kedua model.

Result Analysis

Pada tahap terakhir ini dilakukan penarikan kesimpulan berdasarkan hasil pengolahan data yang telah dilakukan, yaitu model SVM dan Naive Bayes dengan akurasi tinggi terutama dalam mengenali kategori downtime pada data.

Metode Support Vector Machine (SVM)



Support Vector Machine (SVM) adalah metode klasifikasi dalam machine learning (supervised learning) yang memprediksi kelas berdasarkan pola yang dihasilkan dari proses pelatihan [25].

Metode ini digunakan untuk menentukan hyperplane optimal yang memisahkan berbagai kelas dalam ruang vektor [26]. SVM memiliki dua jenis hyperplane linear dan non-linear. Jika data dapat dipisahkan sepenuhnya oleh hyperplane linear, maka disebut SVM linear. Sebaliknya, jika data tidak dapat dipisahkan secara linear, SVM akan menerapkan teknik transformasi kernel untuk memindahkan data ke dimensi fitur yang lebih tinggi agar hyperplane linear dapat terbentuk [27]. Rumus Support Vector Machine (SVM) yang dapat dipisahkan menggunakan fungsi linier adalah sebagai berikut.



$f(x) = + b(6)$

$g(x) = \text{sgn}(f(x))(7)$

Sumber:

[28]

Keterangan:

w= Vektor bobot (arah hyperplane)

x= Vektor fitur (data input)

b= Bias (menggeser posisi hyperplane)

Metode Naive Bayes

Naive Bayes merupakan metode klasifikasi probabilitas yang sederhana dan mengandalkan asumsi independensi tinggi, serta memanfaatkan teorema Bayes [29]. Naive Bayes terdiri dari beberapa jenis, antara lain gaussian, multinomial, dan bernoulli bayes. Pada penelitian ini menggunakan metode Multinomial Naive Bayes, yaitu pendekatan yang menghitung frekuensi istilah dalam dokumen [30]. Berikut adalah rumus untuk metode Multinomial Naive Bayes.

Klasifikasi diawali dengan menghitung probabilitas prior untuk setiap kelas menggunakan estimator maksimum likelihood.



$p() = \pi_k = (8)$

Sumber: [31]

Keterangan:

= Kelas ke-k
p ()= Probabilitas prior kelas
πk= Parameter prior untuk kelas
= Jumlah data yang termasuk kelas
N= Total jumlah data

Pada model Naive Bayes digunakan asumsi conditional independence antar fitur terhadap kelas , sehingga probabilitas bersama fitur dan dinyatakan sebagai berikut:



$p (= p ((9)$
Sumber: [31]
Keterangan:

= Fitur pertama
= Fitur kedua
p = Probabilitas bersama fitur jika diketahui kelasnya
p (= Probabilitas kemunculan fitur pada data yang termasuk kelas
p (= Probabilitas kemunculan fitur pada data yang termasuk kelas

Berdasarkan asumsi conditional independence pada model Naive Bayes, probabilitas posterior kelas setelah mengamati vektor fitur x dapat dinyatakan sebanding dengan hasil kali antara probabilitas bersama fitur dan prior kelas yang dinyatakan sebagai berikut:



$p (\propto p ()(10)$
Sumber: [31]
Keterangan:

p (= Probabilitas posterior, yaitu peluang data termasuk kelas setelah melihat fitur
p (= Probabilitas bersama fitur jika diketahui kelas
p ()= Probabilitas prior kelas

Pada klasifikasi generatif, skor untuk setiap kelas dapat dinyatakan sebagai log dari hasil kali antara likelihood dan prior kelas yang dirumuskan sebagai berikut.



$= \ln p ()(11)$
Sumber: [31]
Keterangan:

p = Probabilitas fitur x jika berasal dari kelas
p ()= Probabilitas awal kelas
III. Hasil dan Pembahasan

Data Collection
Data yang digunakan adalah hasil penggabungan dari dua file, yaitu data sistem hidrolik dan data produksi yang diimpor ke Phyton. Dataset sistem hidrolik memiliki 550 data dengan 6 atribut data, sedangkan dataset produksi memiliki 864 data dengan 2 atribut data. Tabel 2 menjelaskan fitur data yang digunakan dalam penelitian ini.

Tabel 2. Fitur Data Collection
No Tanggal Jenis Aktivitas Keterangan Durasi Downtime (Jam)
1 2022-10-01 Kuratif Perbaikan Penggantian seal hidrolis gate 4
2 2022-10-10 Kuratif Perbaikan Perbaikan aktuator hidrolis 1
3 2022-10-11 Preventif Cek Rutin chain kopling hydrolis pump lepas (ganti ex chain kopling mg007) 3
4 2022-10-12 Kuratif Perbaikan Hidrolis tumbuk rusak 2

...
547 2025-10-02 Kuratif Perbaikan Ganti baut boom hidrolis moulding 1
548 2025-10-09 Kuratif Perbaikan Ganti aktuator hidrolis ex spare 2
549 2025-10-16 Kuratif Perbaikan Repair aktuator hidrolis ex mg007 2
550 2025-10-28 Kuratif Perbaikan Perbaikan mesin hidrolis 3
Pada tabel 2 fitur data collection, data mengenai waktu henti sistem hidrolik dan produksi harian telah tercatat secara menyeluruh melalui variabel tanggal, jenis perawatan, aktivitas, keterangan, dan durasi downtime. Struktur data tersebut menjadi landasan untuk analisis pemodelan kategori durasi downtime sistem hidrolik.

Preprocessing Data
Pada penelitian ini, preprocessing data dilakukan melalui empat tahapan,



yaitu data cleaning, text processing, labeling, dan feature engineering.

Tahap data cleaning meliputi konversi format tanggal, penggabungan dataset, normalisasi durasi downtime, dan penanganan missing values. Selanjutnya, fitur teks dibentuk dengan menggabungkan kolom 'aktivitas' dan 'keterangan' untuk ekstraksi fitur TF-IDF. Label kelas dibagi menjadi tiga kategori durasi downtime, yaitu singkat (<1 jam), sedang (1-3 jam), dan lama (>3 jam). Fitur numerik tambahan dihasilkan dari encoding jenis pemeliharaan dan perhitungan rasio downtime terhadap produksi. Berikut adalah tabel hasil feature engineering.
Tabel 3. Hasil Feature Engineering
No Tanggal Jenis Durasi (Jam) Total Produksi Jenis Kode Rasio Downtime Kategori Downtime

0 2022-10-01 Kuratif 4 2150 0 0,001860 Lama
1 2022-10-10 Kuratif 1 2666 0 0,000375 Sedang
2 2022-10-11 Preventif 3 1376 1 0,002180 Sedang
3 2022-10-12 Kuratif 2 2580 0 0,000775 Sedang

Pada tabel 3 hasil feature engineering, data downtime telah diproses dengan menyesuaikan format tanggal, mengonversi durasi ke dalam angka, menambahkan variabel teks gabungan, serta mengkategorikan durasi menjadi 'Singkat, Sedang, dan Lama'. Selanjutnya, rasio downtime terhadap total produksi telah dihitung agar data siap digunakan sebagai input pemodelan.

Feature Extraction

Fitur teks diubah menjadi representasi numerik menggunakan TF-IDF, kemudian digabungkan dengan fitur numerik untuk model SVM. Gambar 2 menunjukkan feature extraction.

□

Gambar 2. Source Code Feature Extraction TF-IDF

Pada gambar 2, source code feature extraction TF-IDF berfungsi untuk mengonversi teks menjadi bentuk numerik melalui metode TF-IDF sehingga kalimat dapat diolah sebagai fitur oleh model machine learning. Hasilnya adalah matriks nilai TF-IDF yang merepresentasikan tingkat kepentingan masing-masing kata dalam data latih dan data uji.

Split Data

Split data adalah proses pembagian antara data latih dan data uji. Data dibagi menjadi data latih 90% dan data uji 10% dengan stratified sampling untuk menjaga proporsi kelas. Sebelum pembagian, fitur (x) dan label (y) dipisahkan. Fitur terdiri dari dua tipe, yaitu fitur tekstual (x_text) yang mencakup kolom teks, serta fitur numerik (x_num) yang meliputi total produksi, jenis kode, dan rasio downtime produksi. Label (y) adalah kategori downtime yang menjadi target prediksi. Parameter yang digunakan dalam proses pembagian data dapat dilihat pada tabel 4.

Tabel 4. Data Parameter

Parameter Nilai

test_size 0,1

random_state 42

Stratify y (Kategori Downtime)

Total data 550 baris

Data training 495 bari

Data testing 55 baris

Kategori Downtime Singkat, Sedang, Lama

Berdasarkan tabel 4 data parameter, pembagian data dilakukan dengan test_size = 0,1 yang menghasilkan 10% data sebagai data uji dan 90% sebagai data latih. Penggunaan random_state = 42 bertujuan untuk memastikan konsistensi pembagian saat kode dijalankan kembali, sedangkan stratify = y menjaga proporsi setiap kategori durasi downtime pada data latih dan uji agar seimbang dengan data awal.

Algoritma Support Vector Machine (SVM)

Setelah tahap split data selesai dilakukan, tahap berikutnya adalah melakukan pemodelan menggunakan algoritma SVM. Model SVM dioptimalkan menggunakan GridSearchCV dengan 5-fold cross-validation untuk mencari hyperparameter terbaik. Gambar 3 menunjukkan pemodelan SVM.

□

Gambar 3. Source Code Pemodelan SVM

Pada gambar 3 source code Pemodelan SVM menunjukkan kode GridSearchCV yang berfungsi untuk secara otomatis mencari kombinasi parameter terbaik dalam model SVM. Proses ini menguji berbagai nilai dalam param_grid melalui validasi silang 5-fold dan memilih konfigurasi yang memberikan akurasi tertinggi.

Algoritma Naive Bayes

Selanjutnya dilakukan pemodelan menggunakan algoritma Naive Bayes. Model Naive Bayes menggunakan parameter default dan hanya memanfaatkan fitur TF-IDF. Gambar 4 menunjukkan pemodelan Naive Bayes.

□

Gambar 4. Source Code Pemodelan Naive Bayes

Pada gambar 4 source code pemodelan Naive Bayes menunjukkan bahwa model tersebut dibentuk dan dilatih dengan data latih yang telah diubah menjadi fitur numerik sehingga algoritma mempelajari pola keterkaitan antara teks deksripsi downtime dan kategori durasi downtime yang selanjutnya digunakan untuk memprediksi data uji.

Evaluation

Evaluasi model dilakukan untuk mengukur kinerja klasifikasi algoritma SVM dan Naive Bayes pada data uji. Metrik yang digunakan dalam evaluasi meliputi accuracy,



precision, recall, F1-Score, dan Mean Square Error (MSE).

Hasil evaluasi kedua algoritma dapat dilihat pada tabel 5.



Tabel 5. Hasil Evaluasi SVM dan Multinomial Naive Bayes
Model Algoritma Accuracy Precision Recall F1-Score MSE
Support Vector Machine (SVM) 0,

891 0,629 0,429 0,461 0,109

Naive Bayes 0,855 0,285 0,333 0,307 0,145

Pada tabel 5 menunjukkan model SVM menghasilkan evaluasi dengan accuracy sebesar 89,1% yang berarti dapat memprediksi dengan benar 49 dari 55 data uji. Precision mencapai 62,9% mengindikasikan sekitar 63% dari semua prediksi model untuk mendeteksi 43% dari semua kelas, khususnya kelas minoritas 'Singkat' dan 'Lama'. F1-score yang mencapai 46,1% menunjukkan keseimbangan antara precision dan recall. Mean Squared Error (MSE) sebesar 0,109 menunjukkan rata-rata kesalahan prediksi yang rendah dengan label 'Singkat' diubah menjadi 0, 'Sedang' menjadi 1, dan 'Lama' menjadi 2. Sebaliknya, model Naive Bayes memiliki performa lebih rendah dengan akurasi 85,



5%, precision 28,5%, recall 33,3%, F1-score 30,7%, dan MSE 0,

145.

□

Gambar 5. Grafik Perbandingan Model SVM dan Naive Bayes

Pada gambar 5 grafik perbandingan performa menunjukkan bahwa model SVM yang ditunjukkan dengan diagram batang biru lebih unggul dibandingkan model Naive Bayes yang ditandai dengan diagram batang oranye pada semua metrik evaluasi. Keunggulan SVM terletak pada kemampuannya mengelola data dengan fitur kompleks dan memisahkan kelas-kelas yang mirip melalui hyperplane optimal. Sebaliknya, Naive Bayes terbatas oleh asumsi independensi fitur yang tidak sepenuhnya terpenuhi dalam data sensor sistem hidrolik.



□

Gambar 6. Confusion Matrix Model SVM dan Naive Bayes
Selanjutnya,

pada gambar 6 menunjukkan confusion matrix untuk model SVM dan Naive Bayes dalam mengklasifikasikan durasi downtime singkat, sedang, dan lama. Model SVM berhasil memprediksi seluruh 47 data kategori 'Sedang' dengan tepat, tetapi hanya 2 dari 7 data kategori 'Singkat' yang terklasifikasikan dengan benar, sementara 5 lainnya salah diprediksi sebagai 'Sedang'. Untuk kategori 'Lama', 1 data terklasifikasikan sebagai 'Sedang', sehingga tidak ada downtime 'Lama' yang diidentifikasi dengan baik. Model Naive Bayes juga memprediksi semua data kategori 'Sedang' dengan tepat, namun seluruh downtime 'Singkat' dan 'Lama' terklasifikasikan sebagai 'Sedang', sehingga pemisahan kategori di luar kelas 'Sedang' belum optimal. SVM dan Naive Bayes cenderung mengklasifikasikan sebagian besar durasi downtime 'Sedang'. Akibatnya performa pada kelas minoritas 'Singkat' dan 'Lama' menjadi lebih lemah, meskipun akurasi keseluruhan terlihat tinggi. Hal ini mengindikasikan adanya masalah ketidakseimbangan data dan keterbatasan model dalam membedakan pola karakteristik downtime yang singkat atau lama.

Model Comparison

Hasil evaluasi menunjukkan bahwa algoritma SVM memiliki kinerja lebih baik daripada Naive Bayes dalam seluruh metrik yang dianalisis. Pada data uji, SVM mencapai akurasi 0,



891 dengan precision 0,629, recall 0,429, dan F1-score 0,461. Sebaliknya, Naive Bayes memperoleh akurasi 0,855 dengan precision 0,285, recall 0,

333 dan F1-score 0,307. Selain itu, MSE SVM sebesar 0,109 lebih rendah dari Naive Bayes yang mencapai 0,145, menunjukkan bahwa prediksi SVM lebih dekat dengan label sebenarnya. Secara keseluruhan, SVM menunjukkan performa yang lebih stabil dan akurat dalam klasifikasi teks berbasis TF-IDF [32].

Result Analysis

Analisis hasil menunjukkan bahwa SVM memiliki akurasi dan MSE lebih baik daripada Naive Bayes, kedua model tersebut masih cenderung bias terhadap kelas mayoritas 'Sedang'. Hal ini mengakibatkan kemampuan deteksi kelas minoritas 'Singkat' dan 'Lama' yang masih lemah. Berikut adalah gambar 12 yang menunjukkan distribusi aktual dengan prediksi.



□

Gambar 7. Distribusi Aktual dengan Prediksi

Pada gambar 7 terlihat grafik menunjukkan bahwa distribusi data aktual terdiri dari 7 data kategori 'Singkat', 47 data kategori 'Sedang', dan 1 data kategori 'Lama'. Hasil prediksi menggunakan algoritma SVM menunjukkan perubahan menjadi 2 data kategori 'Singkat', 53 data kategori 'Sedang', dan tidak ada data kategori 'Lama'. Sementara itu, prediksi dengan algoritma Naive Bayes mengelompokkan semua 55 data ke dalam kategori 'Sedang' tanpa prediksi untuk kategori 'Singkat' atau 'Lama'. Pola ini menunjukkan bahwa kedua model cenderung memfokuskan prediksi pada kategori 'Sedang' dan belum mampu merepresentasikan kategori 'Singkat' dan 'Lama' dengan baik dalam pemeliharaan prediktif. Kedua model berhasil mengidentifikasi pola utama bahwa sebagian besar durasi downtime tergolong 'Sedang', baik dalam data aktual maupun hasil prediksi. Hal ini menunjukkan bahwa karakteristik downtime 'Sedang' telah direpresentasikan dengan baik oleh model dalam klasifikasi durasi downtime.

□

Gambar 8. Distribusi Kategori Downtime Pada 55 Data Uji

Pada gambar 8 terlihat grafik distribusi prediksi menunjukkan bahwa model SVM linear mengelompokkan 55 data uji dengan 53 kejadian dalam kategori durasi downtime 'Sedang' (1-3 jam) dan 2 kejadian dalam kategori 'Singkat' (<1 jam), sedangkan tidak ada prediksi untuk kategori 'Lama' (>3 jam). Di sisi lain, model Multinomial Naive Bayes mengklasifikasikan semua data dalam kategori 'Sedang' sebanyak 55 kejadian tanpa prediksi untuk kategori lainnya. Pola ini menunjukkan bahwa kedua model lebih fokus pada kejadian downtime berdurasi sedang sehingga hasil klasifikasi dapat dijadikan dasar awal dalam mengelompokkan kategori durasi downtime pada sistem hidrolik untuk penyusunan jadwal perawatan preventif.

Perhitungan Manual Metrik

Berikut adalah perhitungan manual untuk nilai accuracy, precision, dan F1-score yang didasarkan pada gambar 6 hasil confusion matrix model SVM dan Naive Bayes dengan pembagian data latih 90% dan data uji 10%. Langkah-langkahnya adalah sebagai berikut.



Accuracy SVM = = = = 0,891
Accuracy Naive Bayes= = = = 0,

855

Berdasarkan hasil perhitungan tersebut, diperoleh nilai akurasi untuk metode SVM sebesar 0,891 atau 89,1%. Sedangkan metode Naive Bayes menghasilkan nilai akurasi sebesar 0,855 atau 85,5%.

SVM= = = = 1,



00
SVM= = = = 0,887
SVM= = = = 0
Macro Precision SVM = = = 0,629
Naive Bayes= = = 0

Naive Bayes= = = 0,885
Naive Bayes= = = 0
Macro Precision Naive Bayes= = = 0,

285

Berdasarkan hasil perhitungan tersebut, diperoleh nilai precision untuk metode SVM sebesar 0,629 atau 62,9%. Sedangkan metode Naive Bayes menghasilkan nilai precision sebesar 0,285 atau 28,5%.
SVM= = = 0,



286
SVM= = = 1,00
SVM= = = 0
Macro Recall SVM = = = 0,429
Naive Bayes= = = 0
Naive Bayes= = = 1,00
Naive Bayes= = = 0
Macro Recall Naive Bayes = = = 0,

333

Berdasarkan hasil perhitungan tersebut, diperoleh nilai recall untuk metode SVM sebesar 0,429 atau 42,9%. Sedangkan metode Naive Bayes menghasilkan nilai recall sebesar 0,



333 atau 33,3%.
SVM= 2x = 2x = 0,444
SVM= 2x = 2x = 0,940
SVM= 2x = 2x = 0
Macro F1-Score SVM= = = 0,461
Naive Bayes= 2x = 2x = 0
Naive Bayes= 2x = 2x = 0,922
Naive Bayes= 2x = 2x = 0
Macro F1-Score Naive Bayes= = = 0,

307

Berdasarkan hasil perhitungan tersebut, diperoleh nilai F1-score untuk metode SVM sebesar 0,461 atau 46,1%. Sedangkan metode Naive Bayes menghasilkan nilai F1-score sebesar 0,307 atau 30,7%.
Selain menghitung akurasi, presisi, recall, dan F1-score, pemeliharaan prediktif berbasis SVM dan Naive Bayes juga menggunakan nilai MSE untuk menilai rata-rata kuadrat selisih antara keluaran model dan label aktual, sehingga kesalahan prediksi kondisi mesin paving dapat diukur secara kuantitatif dan konsisten. Berikut adalah perhitungan Mean Squared Error (MSE) untuk model SVM dan Naive Bayes:



MSE SVM= = = 0,109
MSE Naive Bayes= = = 0,

145

Berdasarkan hasil perhitungan tersebut, diperoleh nilai MSE untuk metode SVM sebesar 0,109. Sedangkan metode Naive Bayes menghasilkan nilai MSE sebesar 0,145. Metode SVM memiliki MSE lebih rendah dibandingkan metode Naive Bayes, sehingga dapat disimpulkan bahwa SVM memberikan kinerja prediksi yang lebih baik dan akurat dalam penelitian ini.
IV. Simpulan
Hasil prediksi terhadap 55 data uji menunjukkan bahwa model SVM linear mengkategorikan durasi downtime sistem hidrolik mesin paving menjadi tiga kategori, yaitu ‘Sedang’ (1-3 jam) dengan 53 kejadian, ‘Singkat’ (<1 jam) dengan 2 kejadian, dan Lama (>3 jam) tanpa kejadian. Sementara itu, model Multinomial Naive Bayes mengklasifikasikan seluruh data ke dalam kategori ‘Sedang’ sebanyak 55 kejadian tanpa mengidentifikasi kategori lain. Model SVM linear dipilih sebagai yang terbaik karena memiliki nilai MSE lebih rendah (0,



109) dibandingkan Multinomial Naive Bayes (0,

145). Sehingga hasil ini akan digunakan untuk menyusun jadwal perawatan preventif di PT XYZ.

Artikel PSPI_Acopen_Submit.docx | Artikel PSPI_Acopen_Submit
Comes from my group

Ucapan Terima Kasih
Ucapan terima kasih disampaikan kepada Universitas Muhammadiyah Sidoarjo

dan PT XYZ yang telah memberikan kesempatan sehingga proses penelitian dapat dilaksanakan dengan baik.

Referensi
[1]D. M. A. Pratama and W. Widiasih, "Proposed Crane Machine Maintenance Schedule with Reliability Centered Maintenance Method," Product. Optim. Manuf. Syst., vol. 8, no. 2, pp. 104–114, 2024.
[2]I. D. Pranowo, Sistem dan Manajemen Pemeliharaan (Maintenance:



System and Management), 1st ed. Yogyakarta: CV Budi Utama, 2019.
[3]A. Al-khulaqi, N. Palanichamy, S. C. Haw, and S. C.

Raja, "Evaluating Machine Learning and Deep Learning Algorithms for Predictive Maintenance of Hydraulic Systems," Int. J. Adv. Sci. Eng. Inf. Technol., vol. 15, no. 1, pp. 52–59, 2025.

[4]M. A. Ramadhani et al., "Implementasi Algoritma Support Vector Machine (SVM) Untuk Diagnosis Kesehatan Manusia Berbasis Web," J.Ners, vol. 9, no. 1, pp. 896–902, 2025.

[5]Z. Athaullah, M. Munadi, and M. Ariyanto, "Predictive Maintenance Engine Health Monitoring System Pada Excavator Berbasis Machine Learning," J. Tek. Mesin, vol. 13, no. 3, pp. 251–256, 2025.

[6]S.



doi.org | Analysis of Public Sentiment on Twitter Social Media the Design of the Latest Jersey of the Indonesian Football Team using the Support Vector Machine (SVM) Met...
<https://doi.org/10.59934/jaiea.v5i1.1671>

D.

Wahyuni and R. H. Kusumodestoni,
"Optimalisasi Algoritma Support Vector Machine

(SVM) Dalam Klasifikasi Kejadian Data Stunting," Bull. Inf. Technol., vol. 5, no. 2, pp. 56–64, 2024.

[7]F. Amandasari and Damayanti, "Perbandingan Kinerja Support Vector Machine dan Naive Bayes dalam Klasifikasi Sentimen Twitter Terhadap Pelayanan BPJS," J. Pendidik. dan Teknol. Indones., vol. 5, no. 3, pp. 645–653, 2025.

[8]I. G. S. D. Putra and I. N. T. A. Putra, "Implementasi Metode Naïve Bayes Pada Analisis Sentimen Pengguna Aplikasi Mobile Kita Bisa," J. Inform. Dan Tek. Elektro Terap.



, vol. 13, no. 2, pp. 1202–1211, 2025.

[9]M. Nashir, D. A. Kurnia, Y. A. Wijaya, A. I. P. Sari, and N.

D. Nuris, "Perbandingan Kinerja Svm Dan Naive Bayes Pada Analisis Sentimen Komentar Demonstrasi DPR 25 Agustus 2025,"



J. Mhs. Sist. Inf., vol. 7, no. 1, pp. 392–401, 2025.

[10]D. R. Riyantanti and T.

Sukmono, "Predictive Maintenance Pada Mesin Batching Plant Menggunakan Support Vector Machine (SVM)," JATI UNIK J. Ilm. Tek. Dan Manaj. Ind., vol. 8, no. 1, 2024.

[11]M. A. Rasyid, T. Sukmono, and R. B. Jakaria, "Predictive Maintenance on Dry 8 Production Machine Line Using Support Vector Machine (SVM)," J. Tek. Ind. J. Has. Penelit.



dan Karya Ilm. dalam Bid. Tek. Ind., vol. 10, no. 2, pp. 363–373, 2024.

[12]M. Cioch, M. Kulisz,

and A. Gola, "Comparison of Machine Learning Methods in Predictive Maintenance of Machines," Adv. Sci. Technol. Res. J., vol. 19, no. 11, pp. 33–44, 2025.

[13]N. A. Mohammed, O. F. Abdulateef, and A. H. Hamad, "An IoT and Machine Learning-Based Predictive Maintenance System for Electrical Motors," J. Eur. des Syst. Autom., vol. 56, no. 4, pp. 651–656, 2023.

[14]M. Koppula, "Predictive Maintenance To Reduce Machine Downtime In Factories Using Machine Learning Algorithms," Int. J. Adv. Res. Comput. Sci., vol. 16, no. 2, pp. 71–77, 2025.

[15]A. Saylam and H. Atli, "Predictive Analytics for Production Line Downtime: A Comprehensive Study Using Advanced Machine Learning Models," Eur. J. Res. Dev., vol. 3, no. 4, pp. 88–94, 2023.



[16]A.



ojs.udb.ac.id
<https://ojs.udb.ac.id/Senatib/article/view/5299>

Putri et al.,
"Komparasi Algoritma K-NN, Naive Bayes dan SVM untuk Prediksi Kelulusan Mahasiswa Tingkat Akhir,

MALCOM Indones. J. Mach. Learn. Comput. Sci., vol. 3, no. 1, pp.

20–26,

2023.

[17]K. T. Putra, M. A. Hariyadi, and C. Crysdian,

"Perbandingan Feature Extraction TF-IDF dan Bow Untuk Analisis Sentimen Berbasis SVM,"

J. Cahaya Mandalika, vol. 2, no. 2022, pp. 1449–1463, 3AD.

[18]R. Oktafiani, A. Hermawan,



and D. Avianto,

"Pengaruh



dx.doi.org
<http://dx.doi.org/10.34128/jsi.v9i1>

Komposisi Split Data Terhadap Performa Klasifikasi Penyakit Kanker Payudara Menggunakan Algoritma Machine

Learning,”

J. Sains dan Inform., vol. 9, no. April, pp. 19–28, 2023.

[19]A. A. Aqsa, Irawati,

and L. Syafie, “Perbandingan Metode Naïve Bayes dan SVM dalam Analisis Sentimen Netizen Twitter Terhadap Isu Kemenkeu,” Bul. Sist. Inf. dan Teknol. Islam, vol. 4, no. 4, pp. 327–338, 2023.

[20]S. A. S. Mola, R. V. K. I. O. Roma, and T. Widiastuti, Text Mining Analisis Sentimen dengan Lexicon, 1st ed. Bandung: Kaizen Media Publishing, 2025.

[21]P. A. Saputra, S. S. Irawan, Rahmadden, R. Prianto, and T. Hidayat, “Prediksi dan Analisis Pola Perubahan Iklim Menggunakan Algoritma Gradient Boosting,”



JITET (Jurnal Inform. dan Tek. Elektro Ter., vol. 13, no. 2, pp. 431–436,

2025.

[22]M. Gollapalli et al., “Intelligent Modelling Techniques for Predicting Used Cars Prices in Saudi Arabia,” Math. Model. Eng. Probl., vol. 10, no. 1, pp. 139–148, 2023.

[23]K. R. Putra, “Comparison of Prediction Models : Decision Tree , Random Forest , and Support Vector Regression,”



J. Inform. dan Rekayasa Perangkat Lunak, vol. 6, no. 1, pp. 39–49, 2025.

[24]R. Ritonga, I. R. Munthe,

A. P. Juledi, and Masrizal, Optimalisasi Kinerja Pegawai Pertanian Studi Kasus Penggunaan Algoritma Regresi Linear, 1st ed. Kota Malang: PT. Literasi Nusantara Abadi Grup,

2024.

[25]I.



doi.org | Implementasi Support Vector Machine dan Resampling dalam Analisis Ulasan Pengguna Google Maps
<https://doi.org/10.31603/komtika.v9i2.14813>

S. Aisah, B. Irawan,

and T. Suprpti,

“Algoritma Support Vector Machine (SVM) Untuk Analisis Sentimen Ulasan Aplikasi Al Qur’an Digital,”

JATI (Jurnal Mhs. Tek. Inform., vol. 7, no. 6, pp. 3759–3765, 2023.

[26]S. Abimayu, N. Bahtiar,

and E. Adi Sarwoko, “Implementasi Metode Support Vector Machine (SVM) dan t-Distributed Stochastic Neighbor Embedding (t-SNE) untuk Klasifikasi Depresi,” J. Masy. Inform., vol. 14, no.



2, pp. 146–158, 2023.

[27]S.



doi.org | Implementasi Support Vector Machine dan Resampling dalam Analisis Ulasan Pengguna Google Maps
<https://doi.org/10.31603/komtika.v9i2.14813>

Rabbani, D. Safitri, N. Rahmadhani, A.

A. F. Sani, and M. K. Anam,

“Perbandingan Evaluasi Kernel SVM untuk Klasifikasi Sentimen dalam Analisis Kenaikan Harga



doi.org | PERBANDINGAN TEKNIK OPTIMASI GRID SEARCH DAN RANDOMIZED SEARCH DALAM MENINGKATKAN AKURASI METODE KLASIFIKASI SVM PADA SENTIMEN UL...
<https://doi.org/10.36080/skanika.v8i1.3328>

BBM,



ojs.udb.ac.id
<https://ojs.udb.ac.id/Senatib/article/view/5299>

MALCOM Indones. J. Mach. Learn. Comput. Sci., vol. 3, no.

2, pp. 153–160, 2023.

[28]B. Santosa,

Data Mining: Teknik Pemanfaatan Data Untuk Keperluan Bisnis,



1st ed. Yogyakarta: Graha Ilmu, 2007.

[29]R. Hidayat, M. Fikry, Yusra, F. Yanto, and E. P. Cynthia,

“Penerapan



repository.uin-suska.ac.id
<https://repository.uin-suska.ac.id/80539/1/RIZKI%20HIDAYAT.pdf>

Naïve Bayes Classifier dalam Klasifikasi Sentimen Publik di Twitter terhadap Puan

Maharani,”



JUKI J. Komput. dan Inform., vol. 6, no. 1, pp. 100–108, 2024.
[30]N. F. Arminda, N. Sulistiyowati,

and T. N. Padilah, “Implementasi Algoritma Multinomial Naive Bayes Pada Analisis Sentimen Terhadap Ulasan Pengguna Aplikasi Brimo,”



JATI (Jurnal Mhs. Tek. Inform., vol. 7, no. 3, pp. 1817–1822, 2023.
[31]C. M. Bishop, Pattern Recognition and Machine Learning. USA: Springer International Publishing, 2006.
[32]Yusmita, F. Wajidi, and

M. R. Rasyid, “Comparison of SVM and Naive Bayes in Public Sentiment Analysis Regarding Budget Efficiency,” J. Sist. Cerdas, vol. 8, no. 3, pp. 332–342, 2025.



Artikel PSPI_Acopen_Submit.docx | Artikel PSPI_Acopen_Submit
Comes from my group

Conflict of Interest Statement:
The author declares that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.

Conflict of Interest Statement:
The author declares that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.