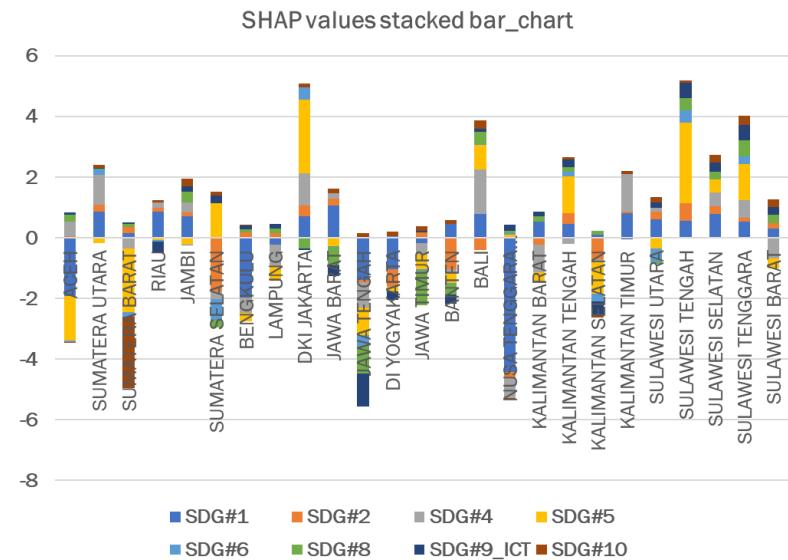


国際会議でのAI分析 発表プレゼンの手法

2024年6月29日

学習院大学経済学部

白田由香利



★1: 自分の名前と所属は覚えてもらうために大きな声ではっきりと

- Today I would like to talk about XXXXX. My name is Prof Shirota from Gakushuin University. I am a professor of Economics Faculty.
- 発表の目的は、自分が発見した成果を皆さんに披露したいため
- プレゼンは「皆さん是非私の話を聞いてください」「私は皆さんにお話をしたいのです」と、話したいオーラを出す。
- 気合いを入れてから壇上へ。気合いの入っていない発表は、極端に言えば、する必要が感じられない

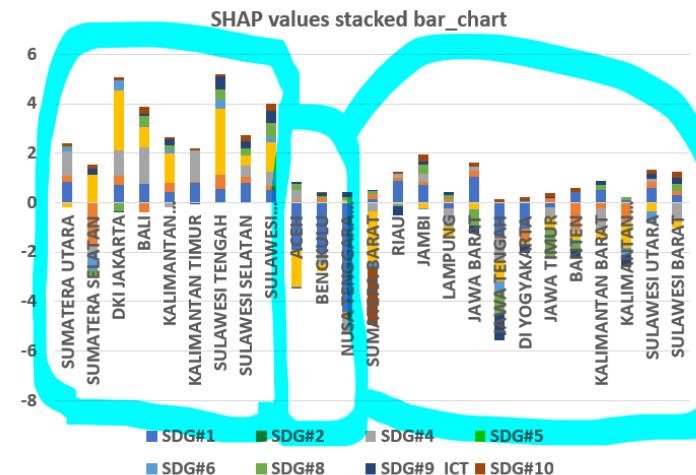
★2: CONTENTSは必ず述べる

- 目次はきちんと説明する。
- ~~本日はこのような内容で話します~~, はダメ
- Firstly, Secondly, Finally I will conclude this presentation.
- 目次項目が変わるたびにこの同じ目次ページを入れること

他人の話は、わかりづらい。
構成をきちんと話して、
今何を話しているのか、
しつこく説明しないと
相手は分からない

Contents

- 1. Research Objective
- 2. Data Selection
- 3. Regression: XGBOOST
- 4. SHAP
- 5. Clustering by SHAP Values
- 6. Conclusion



Let me move on to the next topic which is XXX, と言いながらページをめくる

★3: CONTENTSの中に、 DATAとMETHODSは必ず入れる

- ・分析ではデータと手法
- ・悪い例：回帰なのかクラスタリングなのか、言わずにSHAPの値を説明する。
- ・悪い例：回帰分析で何がターゲットなのか説明変数なのか言わない
- ・データの出典は必須。同じ実験が誰でも可能なように。

・基本の構成

1. Research Objective
2. Data
3. Methods
4. Result
5. Evaluation
6. Conclusions

このセットを
繰り返す

★4: 分析の目的を明確に述べる

目的例

- 教育効果を上げるためにどこに投資すべきか
- Gender equalityの進んでいる地域の特性を探求したい
- 棚卸資産回転率が株価成長に貢献していることを証明したい
- 成長率の高い企業の特質を見たい

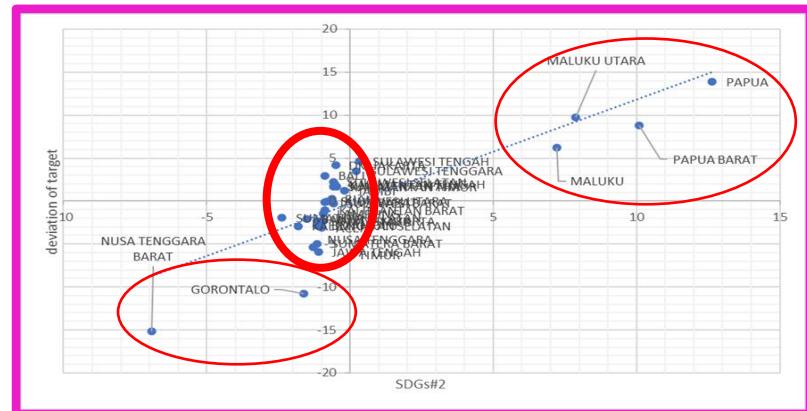
- 目的がはっきりしていないと手法とデータが適切であるか判断できない
- この目的のために、このようなアプローチで分析します、という論理的筋道

★5: 視覚的に見せる。グラフで勝負！

- ・一番重要な結果のグラフは、
タイトルページや、
CONTENTSの余白に張り付け
ておく。
- ・発表開始までの待ち時間に
「これは何だろう」と興味を
もたせる。
- ・グラフがよくできていれば、
少々英語が下手でも伝わる

★6: グラフは軸の説明と単位が必須項目

- そもそも、何のグラフか必ず言うこと。
- 発表でも、軸の説明を口頭で必ず行う
- This axis shows と言って、軸をレーザーpointerでなぞる



- 「結果はこうなります」だけではダメ
- 他人はどこがすごいのか、言われなくては分かりません。
- The largest target value is this というようにポイントする。
- 注目点は、予め、円で囲むか、矢印をつけておく。ひと手間を惜しんではいけない。

★7: 問いかけを効果的に入れて、話についてこさせる

- Among the 3 clusters, which cluster has the highest performance?
- Which pair offers higher similarity?
- What is this data?
- 考えさせて、理解させる。
この間が重要。
- 値を2つ並べられても、大きい方が優れているのか、小さいほうが優れているのか、聞いている人には判断がつかない。
 - どっちが優れているの？？？
 - しっかりと「こちらが良い」と言う。

★8: 原稿を読まない。 観客に背中をむけない。

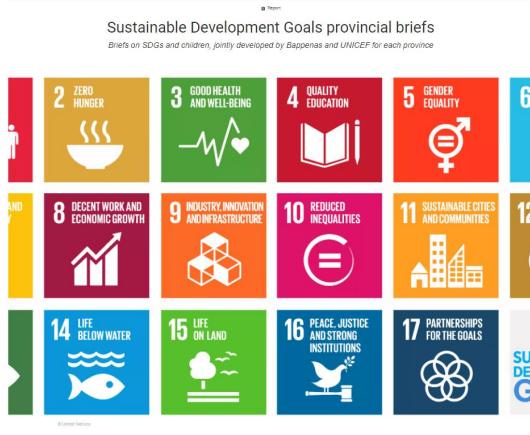
- ・ぼそぼそ原稿を読むだけでは、観客は寝るか、ケータイを始める。
- ・そもそも、何か伝えたいという積極的態度がないのがいけない。
- ・自分が伝えたいことを、相手に伝える。
- ・英語が話せないなら、英語をp p tに書き込んでおく
- ・目を合わせなくてもよいので、Are you with me?と心の中で念じながら、時々、聴衆のほうを見るともなく見る。

★9: 英語は伝わるように発音する

- ・発音の訓練は時間がかかるので日頃からトレーニングする
- ・イギリス英語よりもアメリカ英語のほうが伝わりやすいZOOMプレゼンで痛感した。
- ・間違った発音でも、大きく自信をもって話そう
- ・声が大きいほうが、よく伝わる

★10: 要所要所でそこまでのCONCLUSIONS 最後のCONCLUSIONSは時間たっぷりとする

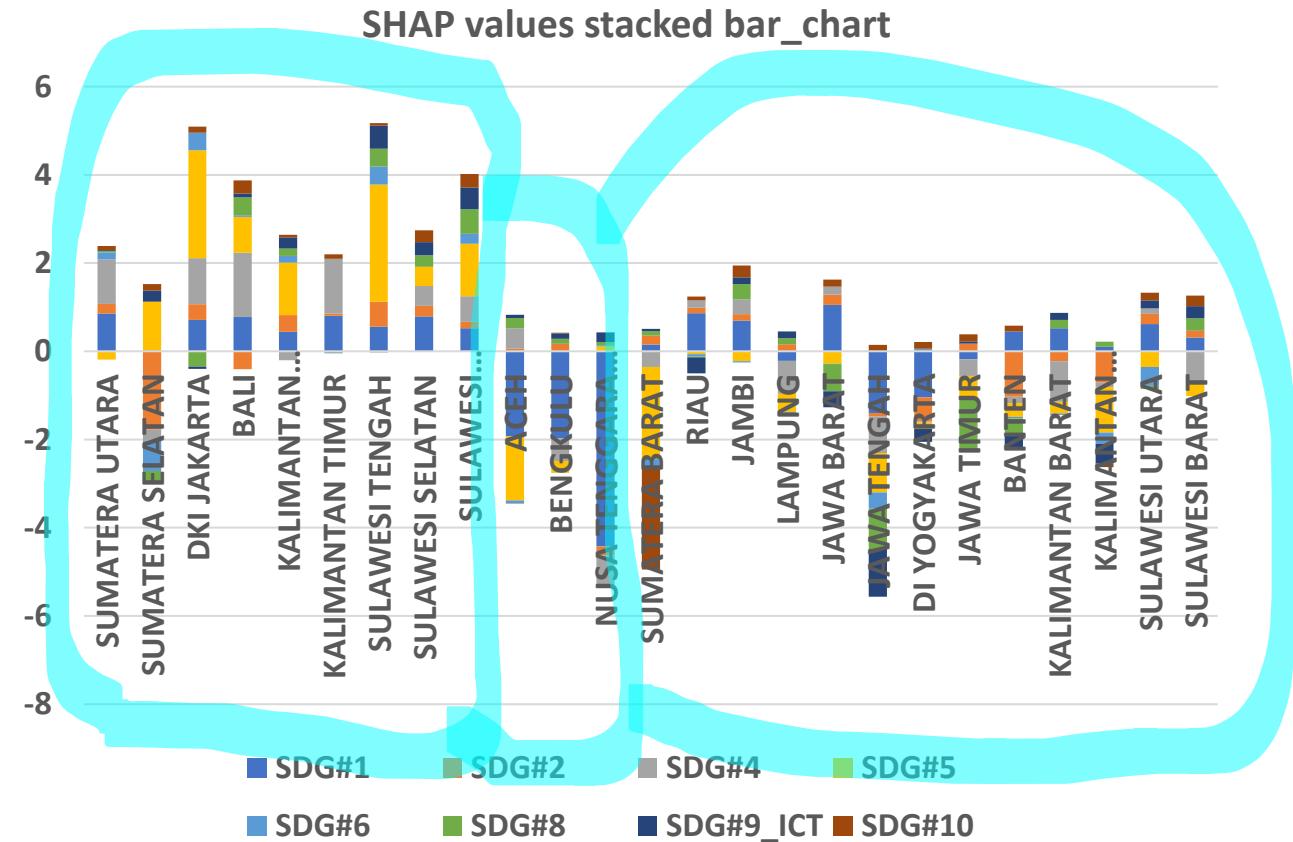
- ゆっくり話していると時間がなくなる
- CONCLUSIONSに時間をたっぷり残す
- CONCLUSIONSでは、そこだけ聞いても話の内容がわかるようにな要にして完、にまとめる
- 重要なグラフはべたべた張り付ける
- まとめは、今後のプロジェクト資金がとれるかとれないかの瀬戸際と思って（そうでなくとも）真剣に伝える。



Shapley-based Analysis of Dominant Factors for Well-being Achievement by Indonesia Provinces

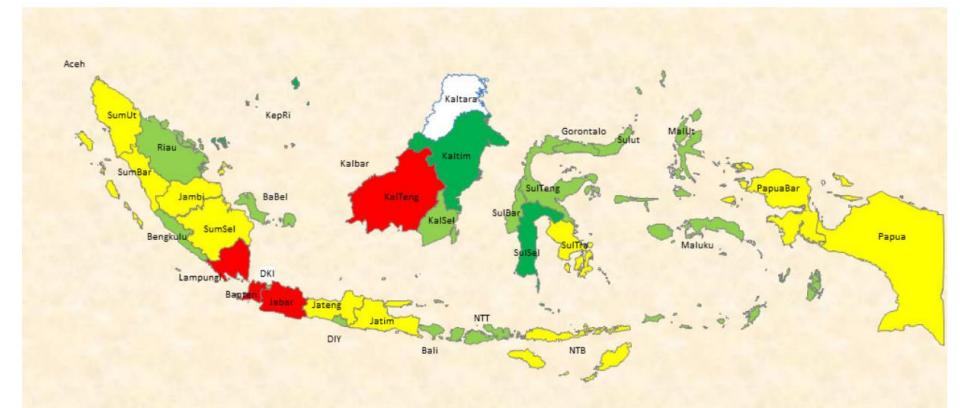
Contents

- 1. Research Objective
- 2. Data Selection
- 3. Regression: XGBOOST
- 4. SHAP
- 5. Clustering by SHAP Values
- 6. Conclusion



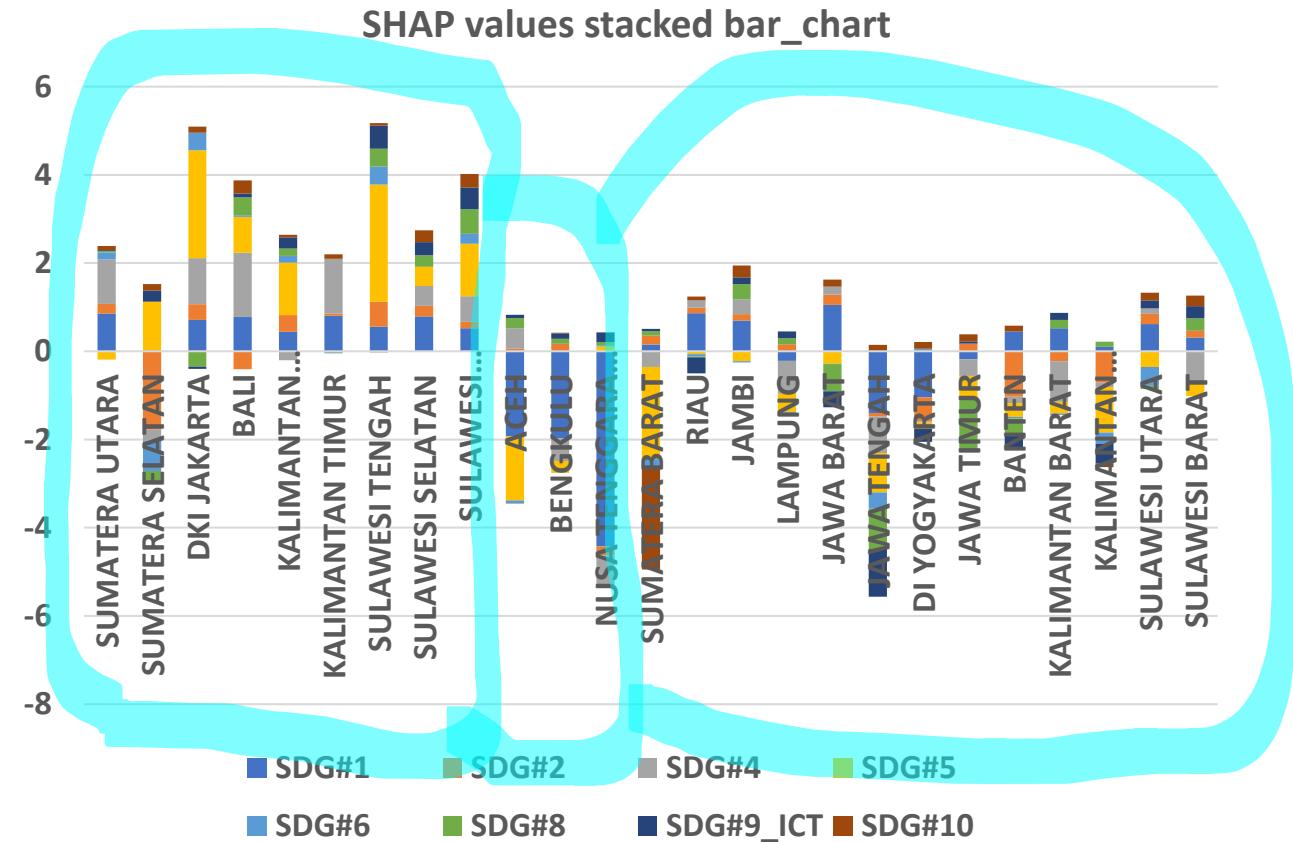
Research Objective and Approach

- Among 17 SDG scores, which factors are dominant to increase well-being scores?
- Effective investment by the government
- Data: data by provinces from **BADAN PUSAT STATISTIK**
- Method: AI-based regression XGBoost
- XAI (eXplainable AI) tool: SHAP



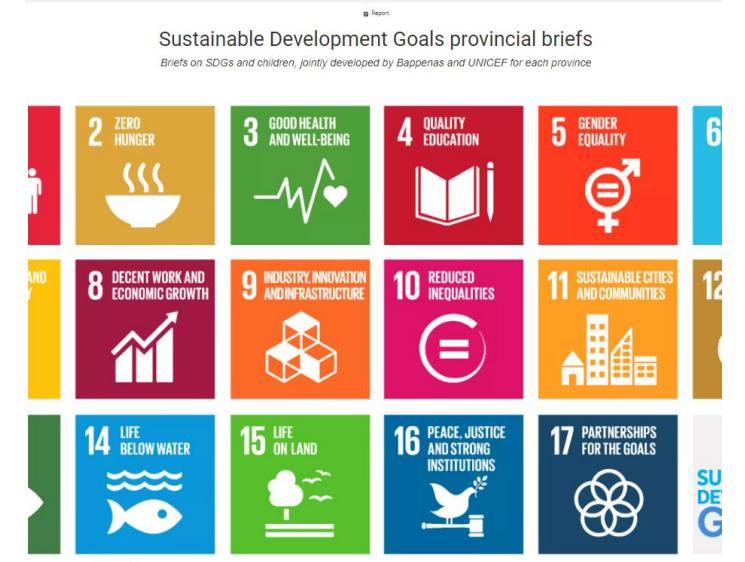
Contents

1. Research Objective
2. Data Selection
3. Regression: XGBOOST
4. SHAP
5. Clustering by SHAP Values
6. Conclusion



Data Selection

- SDGs#1: [NotPoor%]=100 – [Percentage of Poor Population (P0) by Province and Area (Percent), cited from [1]]
- SDGs#2: NotHungryLevel, [Daily Average Consumption of Calorie and Protein per Capita]
- SDGs#3: [Well-being%]=100 - [Percentage of Population Having Health Complaint by females]
- SDGs#4: [Completion Rate by Educational Level and Province: Senior High School %]
- SDGs#5: [Gender Empowerment Index]
- SDGs#6 [Households Using Safely Managed Sanitation Services (%)]
- SDGs#8: [GDP%] = [[2010 Version] Distribution of GRDP to Total GRDP of 34 Provinces at Current Market Prices by Province (Percent)]
- SDGs#9: [ICT%] = [Proportion of Adults (Aged 15-59 Years) with Information and Communication Technology Skills (Percent)]
- SDGs#10: [NoEconomicDisparityLevel] = (-1) Standardized value of Gini index

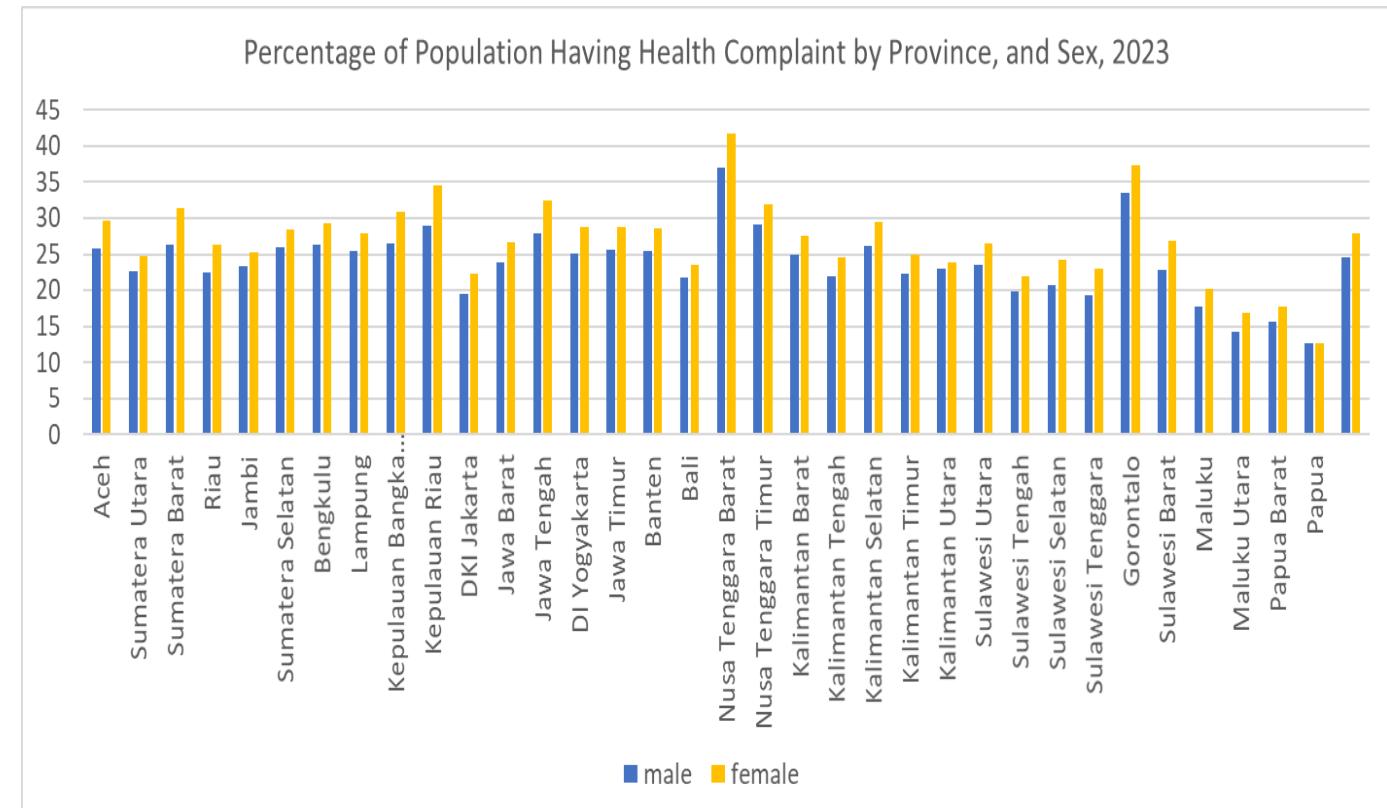


Cited: <https://www.unicef.org/indonesia/reports/sustainable-development-goals-provincial-briefs>

Percentage of Population Having **Health Complaints** by females as Well-being index

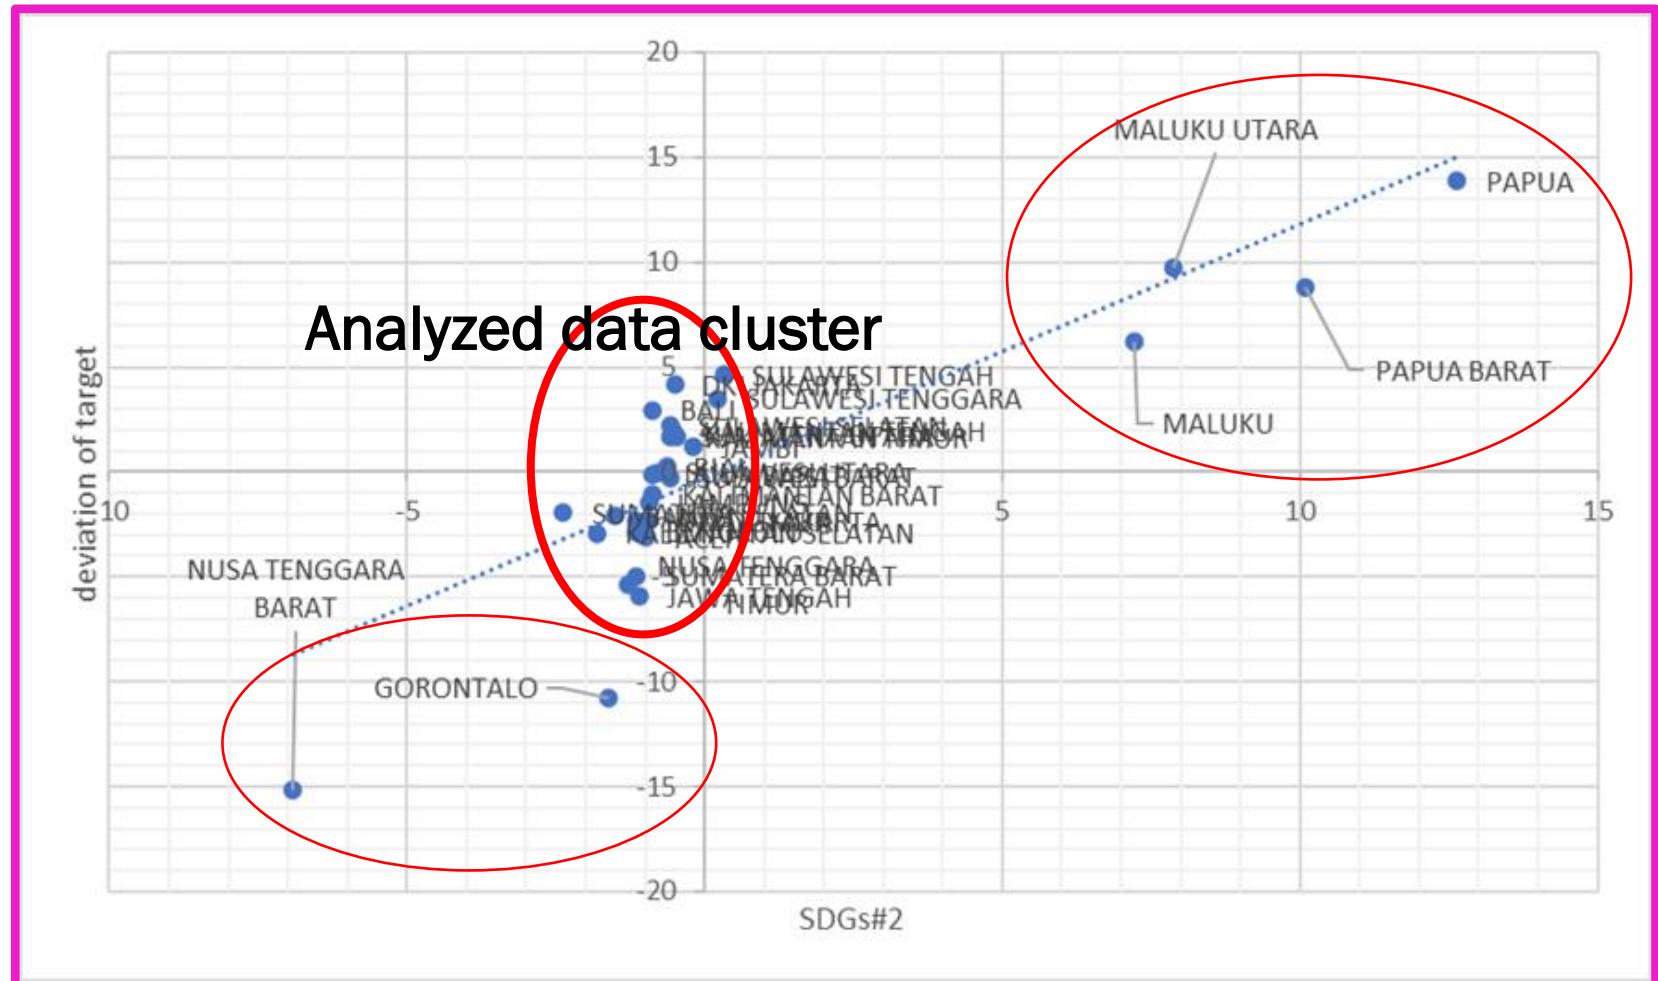
- Comparison between complaints by male/female
- In every province higher % of complaints by female than by male
- Perhaps females' positions are more vulnerable
- Target variable:

[Well-being%]=
“100 - this female %”



SDGs#2[NotHungry%] vs [Well-being%] in 2023

- Papua has the highest well-being%
- Focused on the center cluster 25 provinces



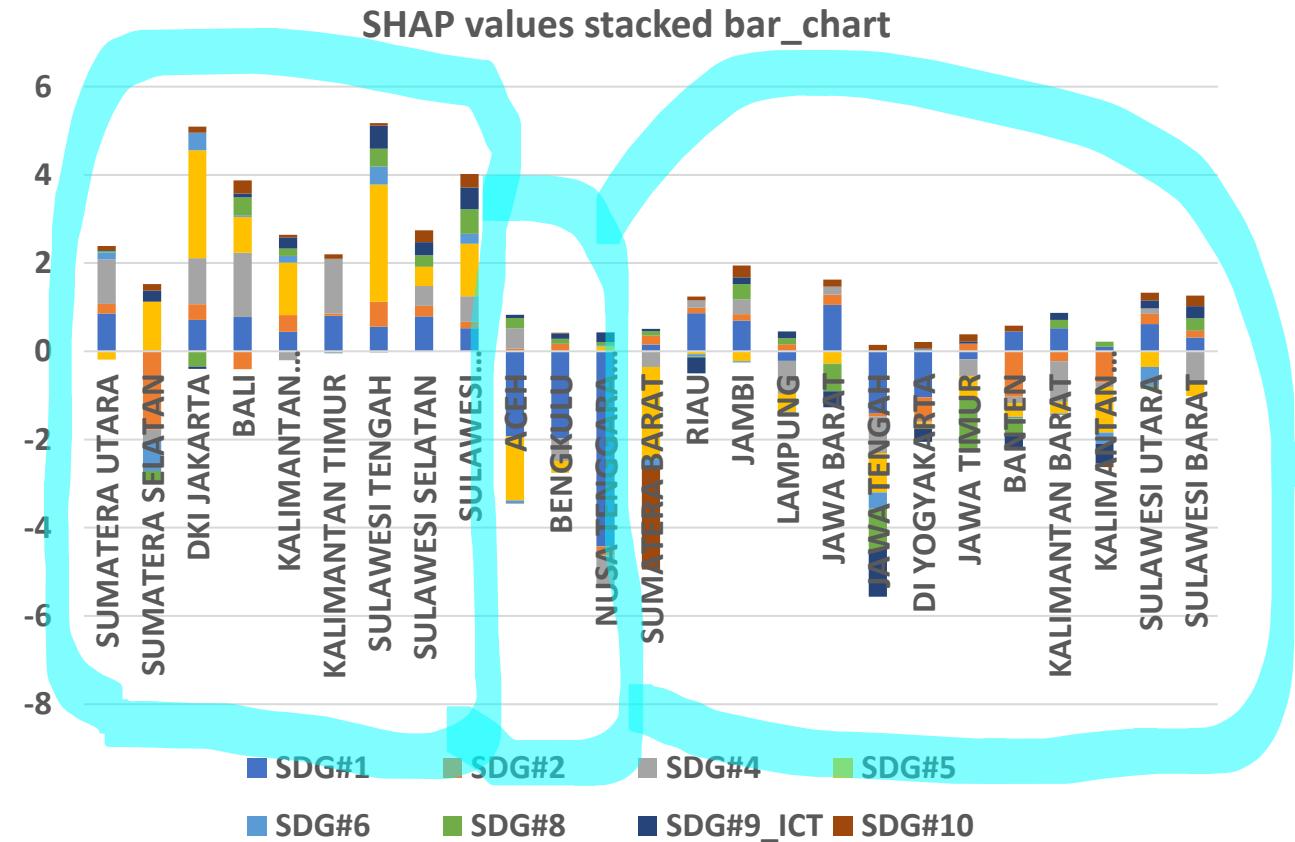
Correlation Coefficients among Variables before Regression

- 8 Explanatory Variables
- No explanatory var. highly correlated to TARGET

	SDG#1	SDG#2	TARGET : SDG#3	SDG#4	SDG#5	SDG#6	SDG#8	SDG#9_I CT	SDG#10
SDG#1	1.00								
SDG#2	0.49	1.00							
TARGET:SDG#3	0.39	0.24	1.00						
SDG#4	0.48	0.43	0.29	1.00					
SDG#5	0.10	0.13	0.23	0.03	1.00				
SDG#6	0.43	0.41	0.18	0.72	0.07	1.00			
SDG#8	0.24	0.14	0.11	0.31	0.11	0.47	1.00		
SDG#9_I CT	0.70	0.34	0.25	0.81	0.13	0.63	0.47	1.00	
SDG#10	-0.10	-0.20	-0.16	-0.46	-0.41	-0.41	-0.54	-0.51	1.00

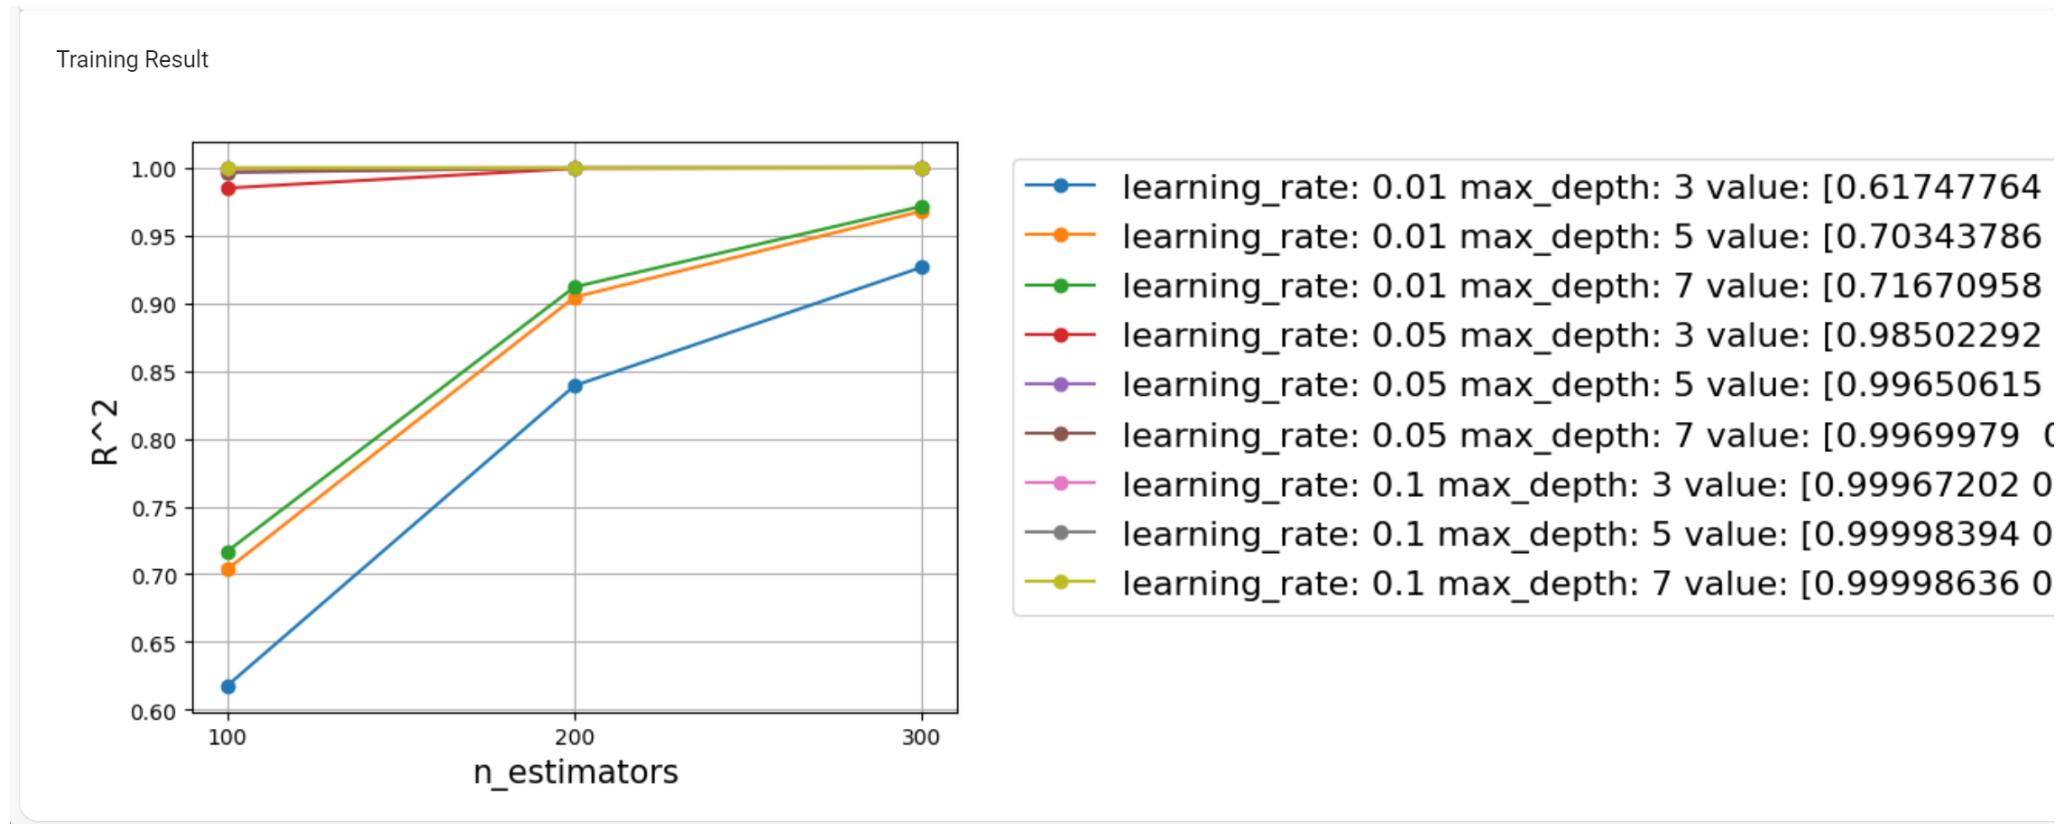
Contents

1. Research Objective
2. Data Selection
- 3. Regression: XGBOOST
4. SHAP
5. Clustering by SHAP Values
6. Conclusion



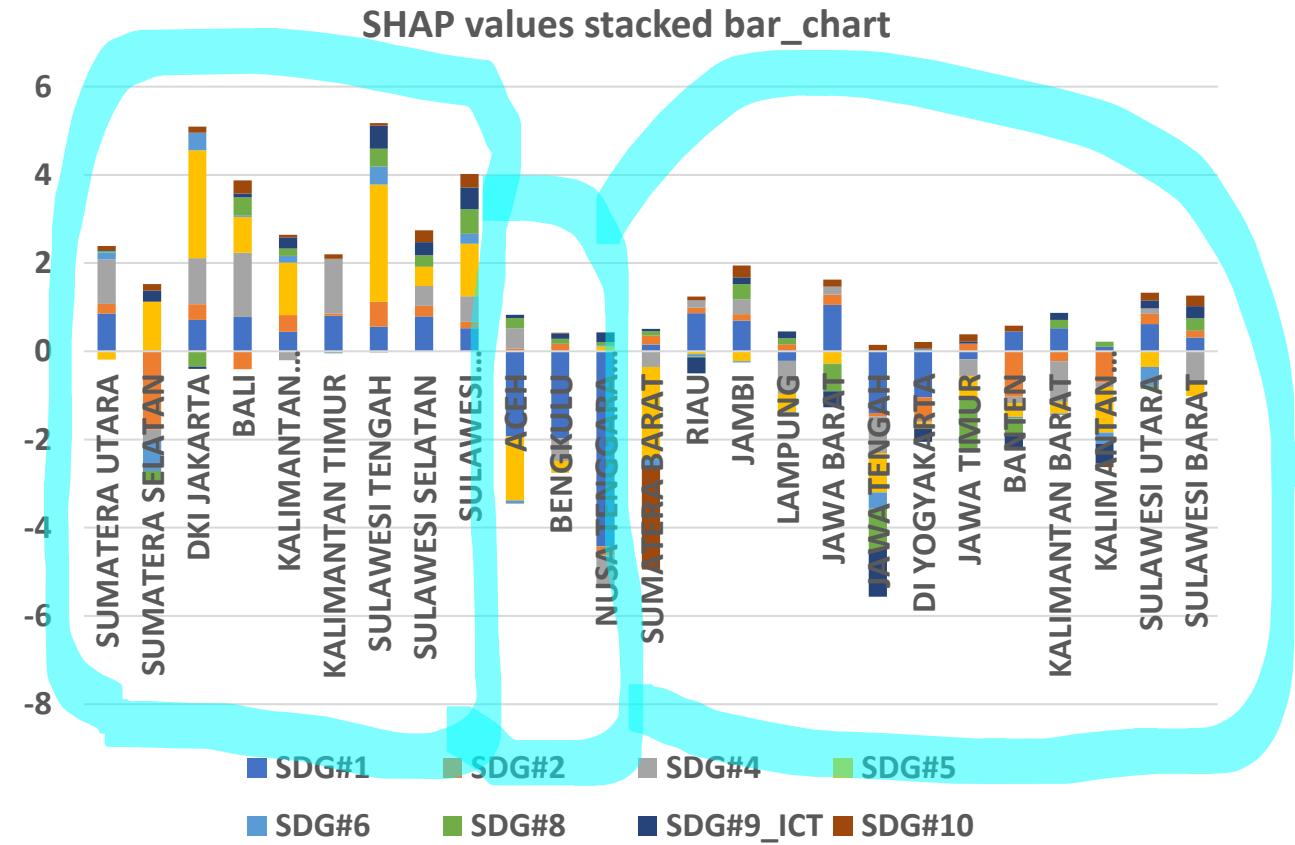
XGBoost Regression

- R²: Almost 1.0 by the best parameter set



Contents

1. Research Objective
2. Data Selection
3. Regression: XGBOOST
4. SHAP 
5. Clustering by SHAP Values
6. Conclusion



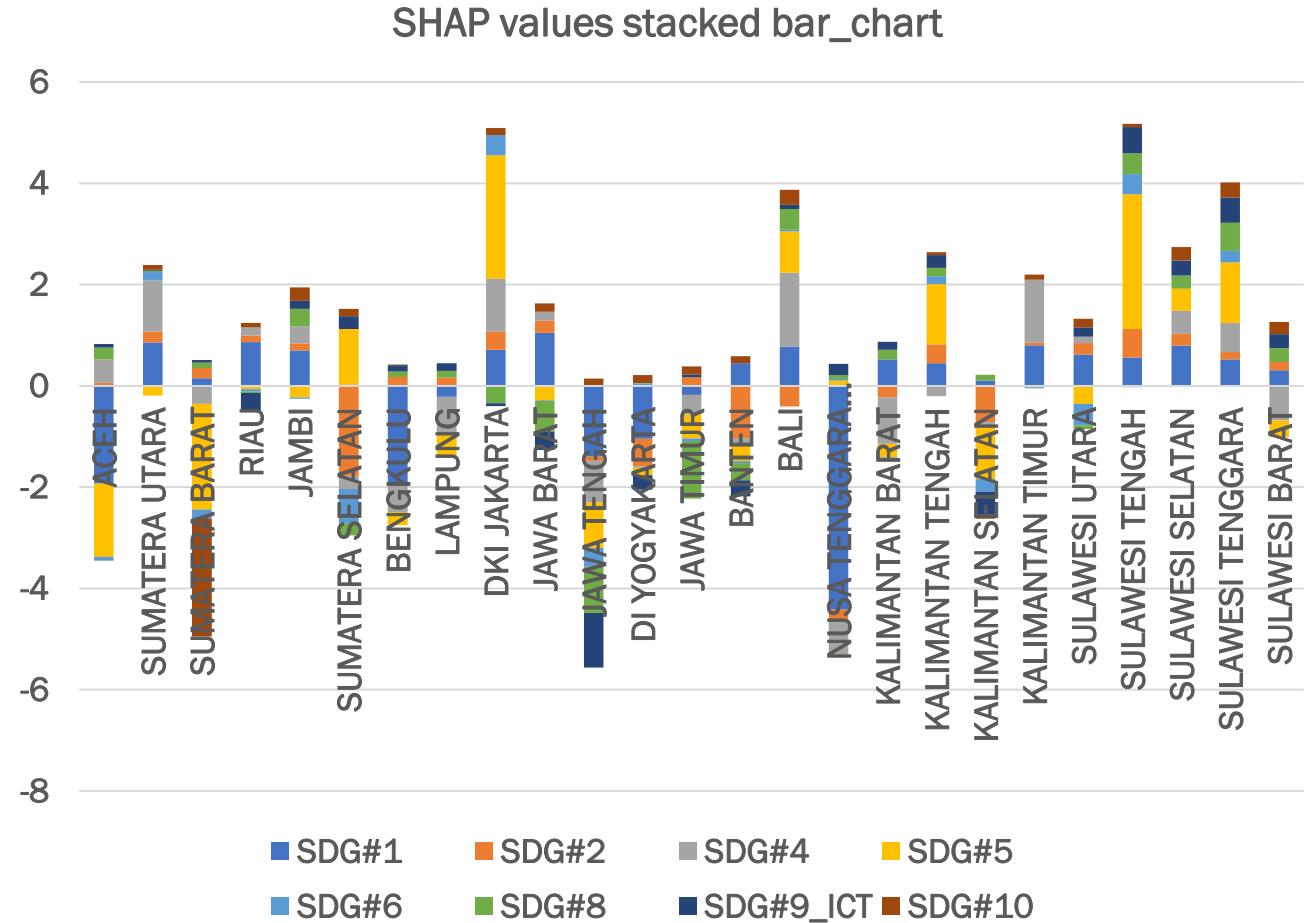
SHAP

- Using the resultant regression model $f(X)$, SHAP values can be calculated.

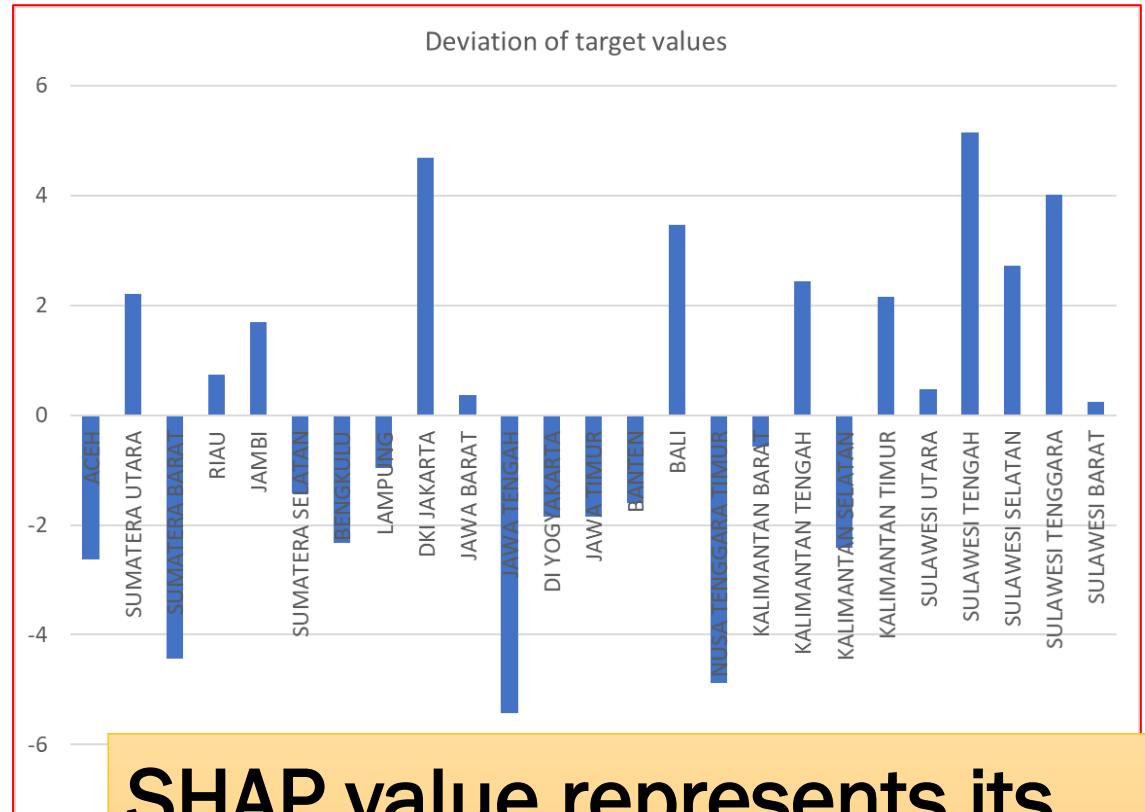
- DBKDA 2023 **tutorial** video by Shirota and Basabi
Theoretical Explanation and Case Studies of Shapley Values in Machine Learning Regression
 - <https://www.youtube.com/watch?v=ml214YIY0oc>
<https://www.iaria.org/conferences2023/TutorialsDBKDA23.html>

SHAP

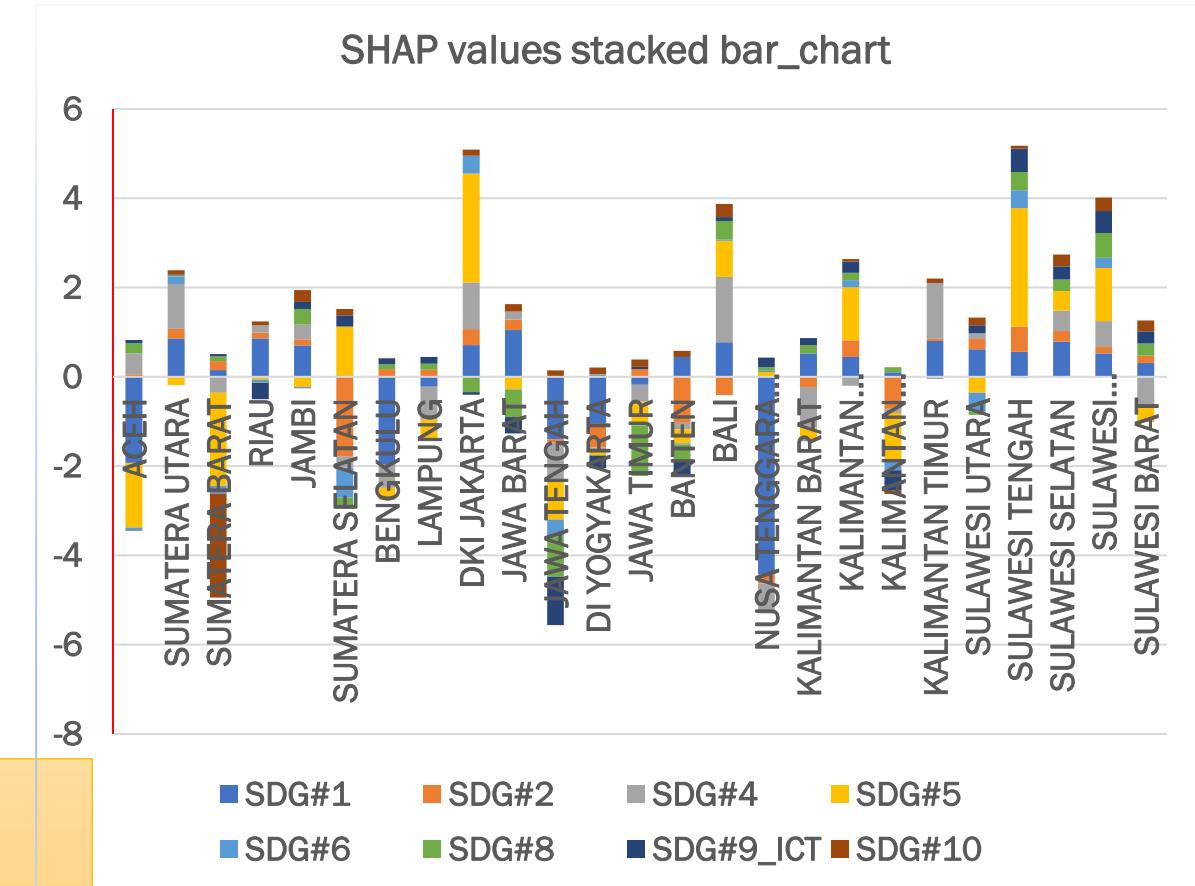
- Each province data has 8 SHAP values.
- Y-axis: deviations of target values (target – average)
- SHAP values may be negative
- The sum of the 8 SHAP values becomes the deviation of the target value in each province.



Target Deviation and Stacked Bar_chart of SHAPs

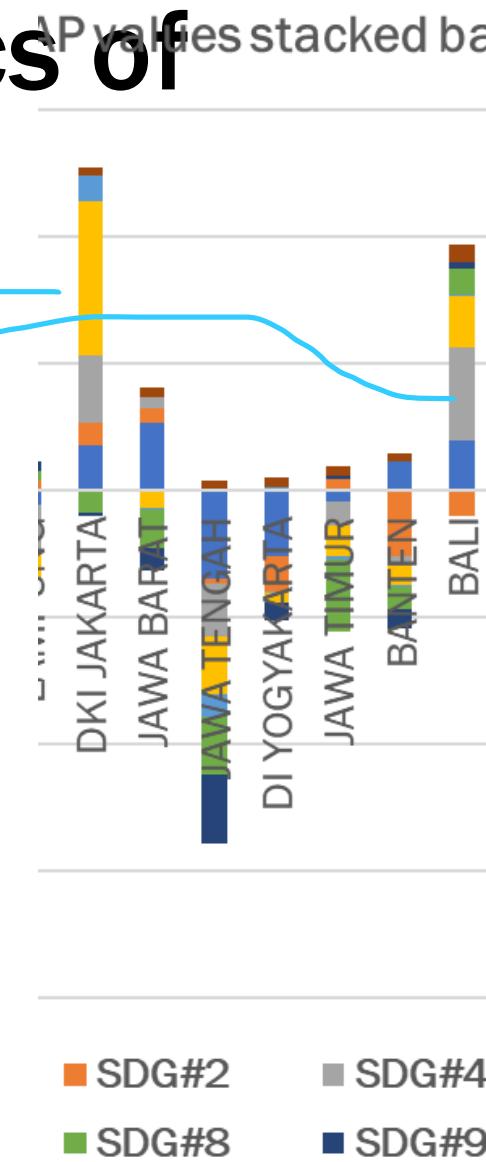


SHAP value represents its contribution to the target value



SHAP shows Characteristics of Each Province

- DKI Jakarta: dominant factor is SDG#5 (gender)
- Bali: dominant factor is SDG#4 (education)
- The 8 variables' contributions are up to the province.
- Using its **characteristics**, measure the effectiveness of each index variable



Which var is the dominant factor to well-being? Correlation coefficients among SHAP and target

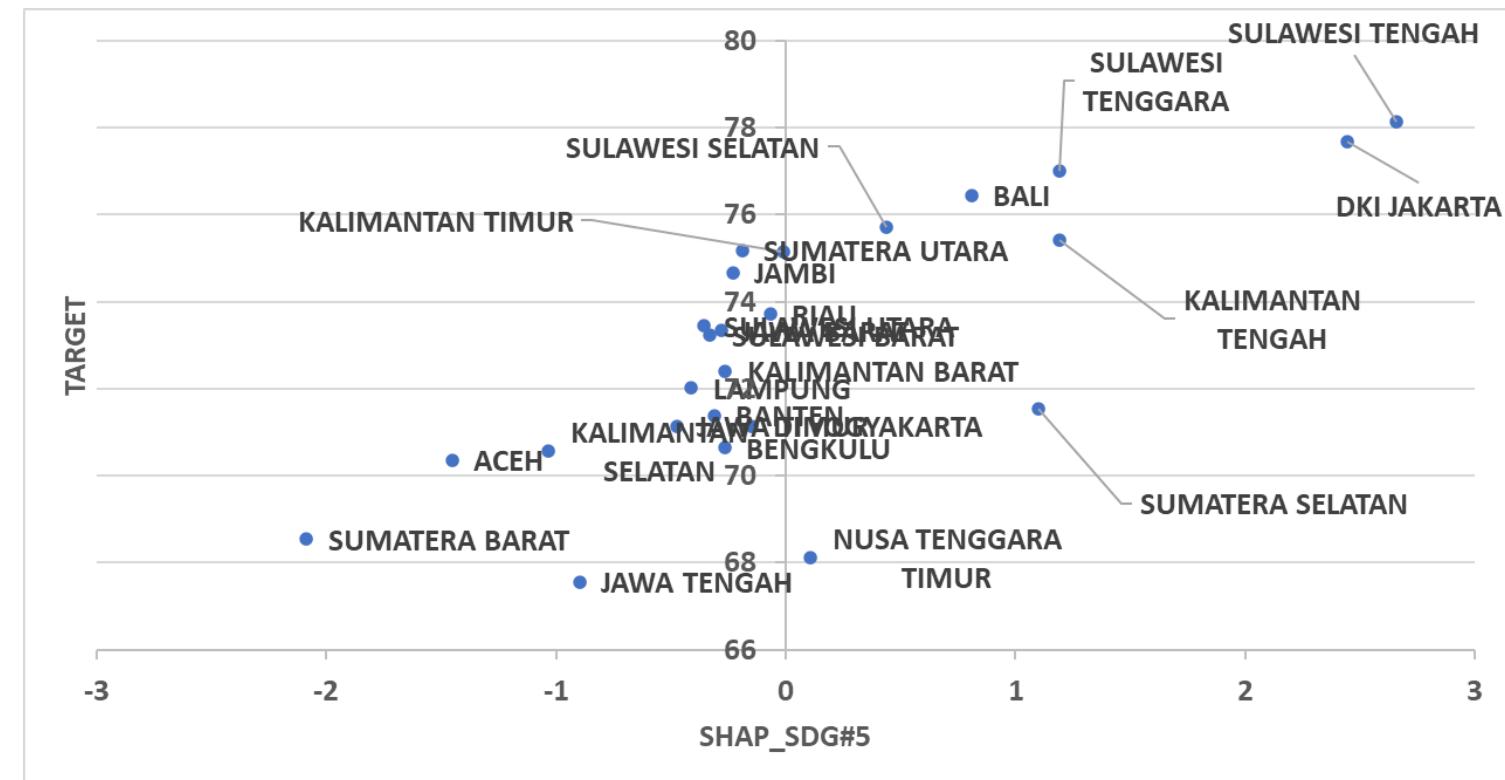
1. SDG#5 (gender) has the highest value 0.76
2. SDG#1 (NoPoor) 0.68
3. SDG#4 (Education) 0.66

SHAP/TARGET	SDG#1	SDG#2	SDG#4	SDG#5	SDG#6	SDG#8	SDG#9_ICT	SDG#10	TARGET:SDG#3
SDG#1	1.00								
SDG#2	0.13	1.00							
SDG#4	0.44	0.13	1.00						
SDG#5	0.25	0.09	0.33	1.00					
SDG#6	0.12	0.60	0.34	0.51	1.00				
SDG#8	0.08	0.13	0.23	0.19	0.32	1.00			
SDG#9_ICT	0.09	0.22	0.12	0.43	0.33	0.62	1.00		
SDG#10	0.06	-0.09	0.21	0.45	0.14	-0.05	0.01	1.00	
TARGET:SDG#3	0.68	0.36	0.66	0.76	0.60	0.40	0.49	0.40	1.00

Scatter Plot between SDG#5_SHAP and target : 0.76

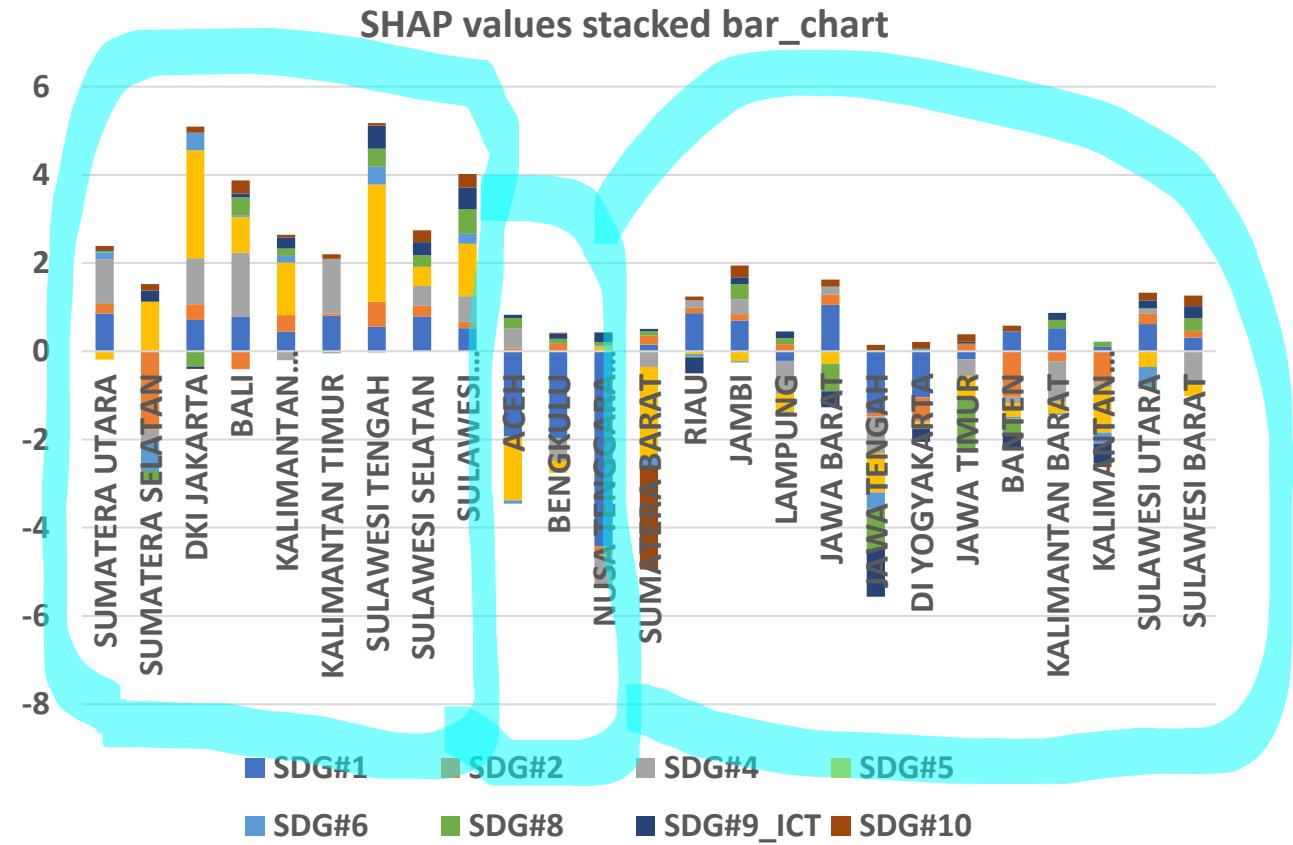
- Highest SDG#5_SHAP

1. SULAWESI TENGAH
2. DKI JAKARTA
3. SULAWESI TENGGARA
4. KALIMANTAN TENGA



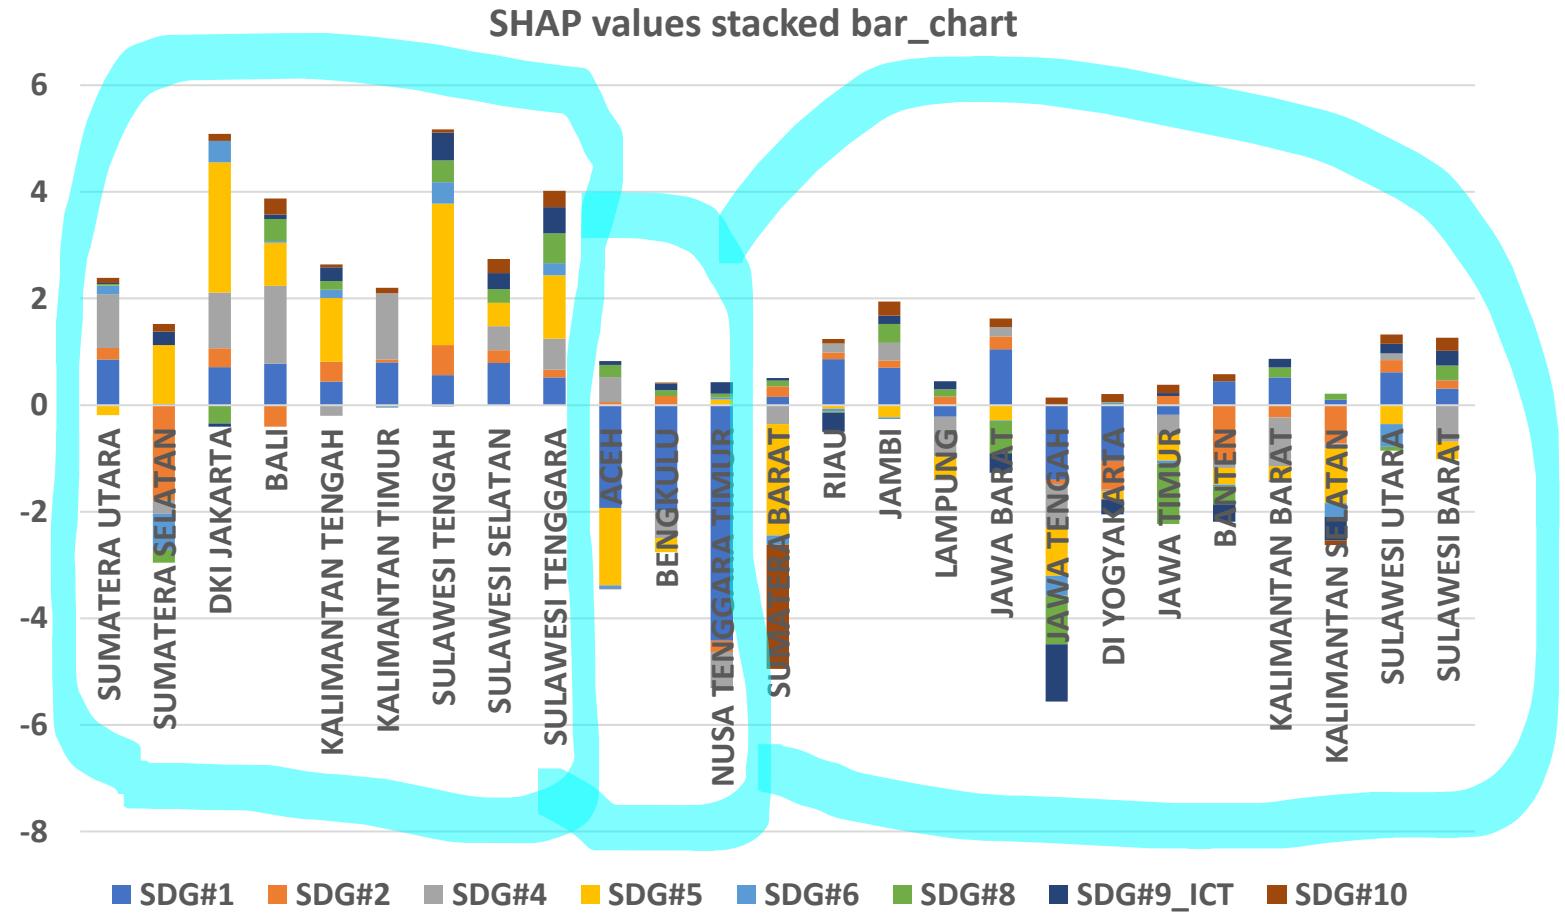
Contents

1. Research Objective
2. Data Selection
3. Regression: XGBOOST
4. SHAP
- 5. Clustering by SHAP Values
6. Conclusion



Clustering by SHAP distribution pattern

- 3 clusters



Clustering by 8 SHAP Values

- K-means
- The number of clusters **k=3**

Name	SDG#1_s1	SDG#2_s1	SDG#4_shapvalue	SDG#5_s1	SDG#6_s1	SDG#7_s1	SDG#8_s1	SDG#9 IC	SDG#10_s1
ACEH	-1.32654	0.212461	0.5003764	-1.70384	0.008896	0.096279	-0.04466	-0.04872	-0.3157
SUMATER	0.323192	0.05647	1.4388171	-0.173	0.041875	0.303295	0.332676	-0.05031	-0.07491
SUMATER	0.0088	-0.00718	-0.69242096	-2.03179	-0.05423	0.001329	-0.10816	-0.06959	-1.48705
RIAU	0.097818	0.431496	-0.12935348	-0.19001	0.020559	0.410955	0.248114	-0.03034	-0.12018
JAMBI	0.228608	0.543912	-0.04496461	-0.07918	-0.02021	0.449312	0.210442	-0.02564	0.425004
SUMATER	0.064943	-0.82872	-0.20721847	0.22851	-0.63826	0.17615	0.037068	-0.05305	-0.21058
BENGKUL	-1.43052	-0.09703	-0.38009563	-0.09457	-0.15745	0.115303	-0.0582	-0.04536	-0.18407
LAMPUNG	0.200032	-0.05438	-0.4760555	-0.17452	-0.15737	0.158617	-0.04391	-0.07555	-0.33855
DKI JAKARTA	0.499201	0.294244	1.0982153	1.402713	0.380063	0.298922	0.132814	0.239914	0.341256
JAWA BARAT	0.225541	-0.0375	-0.10031061	-0.27548	0.002049	0.118123	-0.06808	-0.00415	0.49775
JAWA TEN.	-0.53864	0.072779	-0.39650568	-1.18475	-0.00879	-3.34553	-0.00563	-0.0394	0.025324
DI YOGYA	0.508485	0.034989	0.340477	0.265698	0.020533	-3.0429	-0.17284	0.088556	0.115681
JAWA TIM.	0.06426	-0.08567	-1.0101215	-0.94568	-0.0576	0.050973	-0.15073	-0.06531	0.359153
BANTEN	0.07224	-0.39842	-1.0393312	-0.1532	0.074785	0.09938	-0.21814	-0.03623	-0.00139
BALI	0.66559	-0.07583	1.5194385	0.158591	0.090098	0.347438	0.210376	0.258025	0.293991
NUSA TEN.	-2.48124	-0.44546	-0.4487205	-1.06701	-0.12665	0.108841	-0.12152	0.06561	-0.35443
KALIMAN	0.265338	-0.06634	-0.30994222	-0.20193	-0.09781	0.320106	-0.04288	-0.04889	-0.3891
KALIMAN	0.226552	0.148986	-0.047996495	1.689522	0.187477	0.354901	0.071199	-0.04646	-0.14595

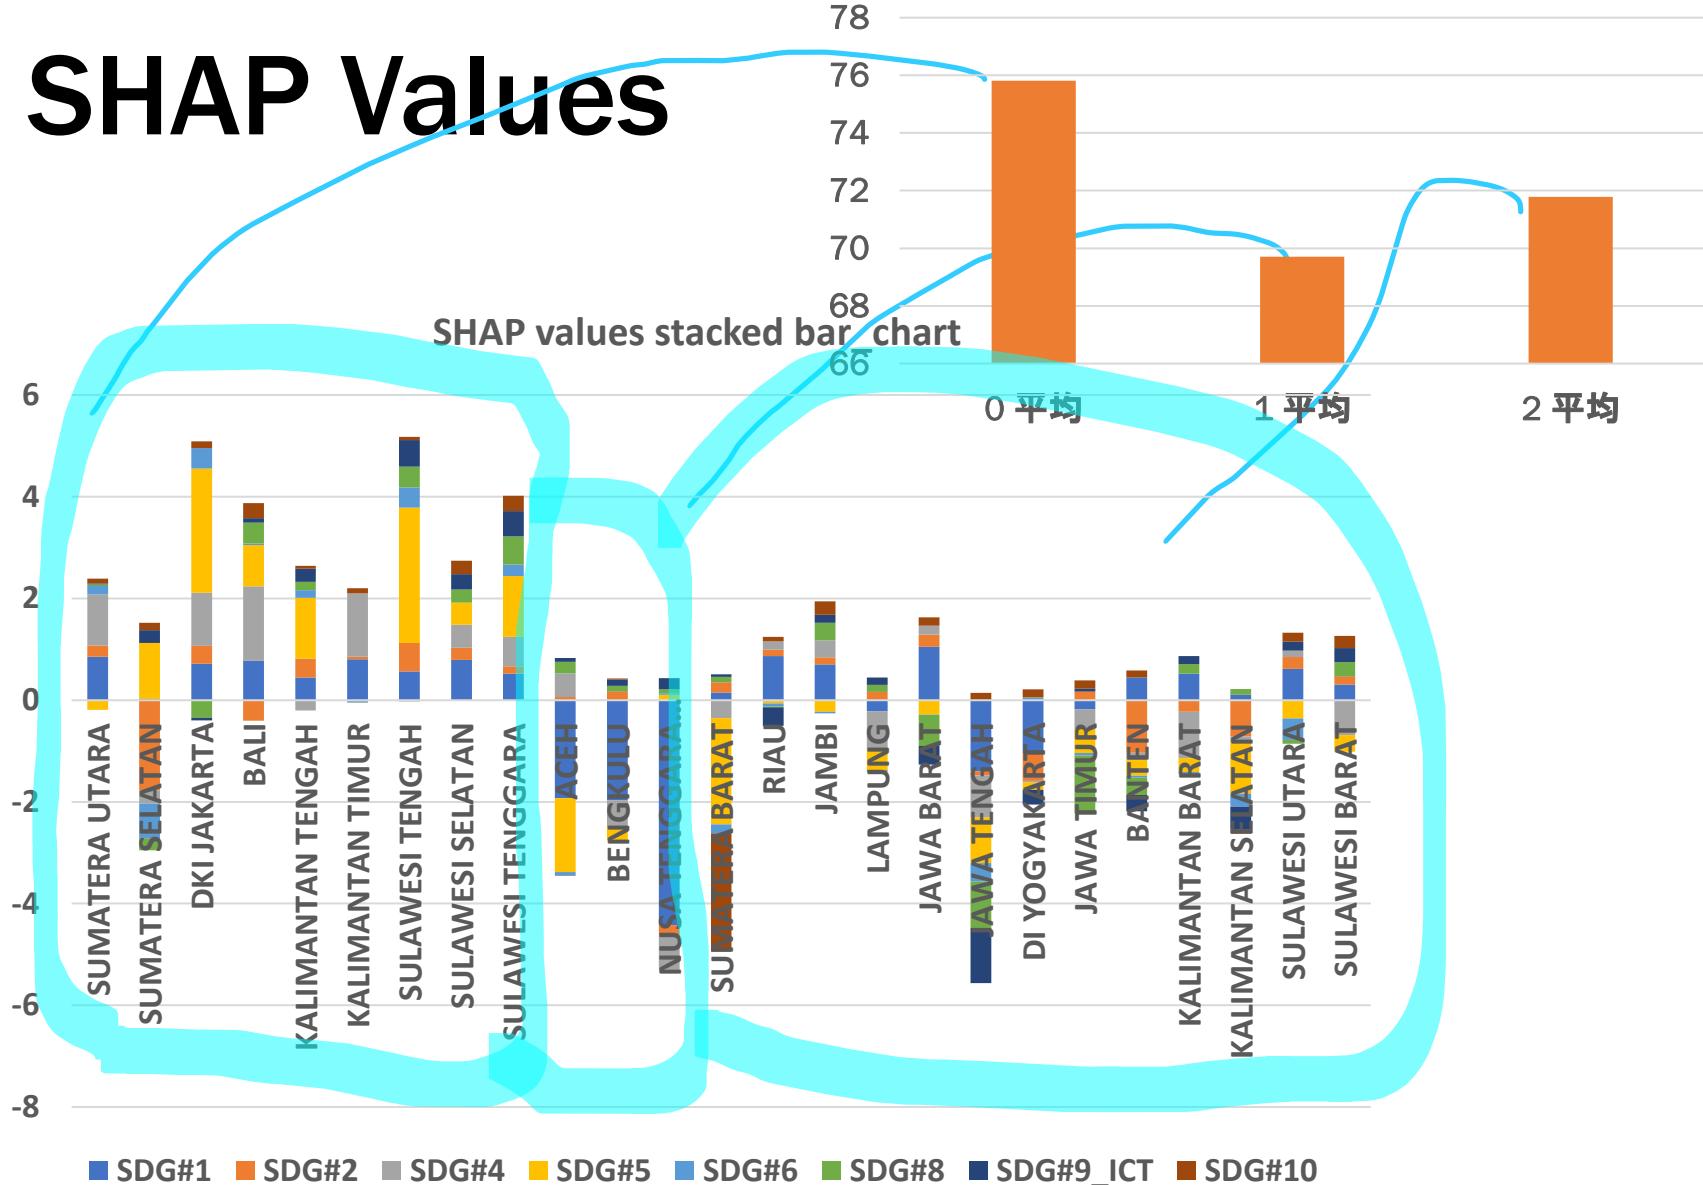
Find Average SHAP Values of Each Cluster

- Resultant LABEL ID

Name	LABEL_ID	SDG#1_sh	SDG#2_sh	SDG#4_shapvalue	SDG#5_sh	SDG#6_sh	SDG#7_sh	SDG#8_sh	SDG#9_IC	SDG#10_sh	SDG#3
ACEH	2	-1.32654	0.212461	0.5003764	-1.70384	0.008896	0.096279	-0.04466	-0.04872	-0.3157	70.36
SUMATER	0	0.323192	0.05647	1.4388171	-0.173	0.041875	0.303295	0.332676	-0.05031	-0.07491	75.18
SUMATER	2	0.0088	-0.00718	-0.69242096	-2.03179	-0.05423	0.001329	-0.10816	-0.06959	-1.48705	68.54
RIAU	0	0.097818	0.431496	-0.12935348	-0.19001	0.020559	0.410955	0.248114	-0.03034	-0.12018	73.72
JAMBI	0	0.228608	0.543912	-0.04496461	-0.07918	-0.02021	0.449312	0.210442	-0.02564	0.425004	74.67
SUMATER	2	0.064943	-0.82872	-0.20721847	0.22851	-0.63826	0.17615	0.037068	-0.05305	-0.21058	71.55
BENGKUL	2	-1.43052	-0.09703	-0.38009563	-0.09457	-0.15745	0.115303	-0.0582	-0.04536	-0.18407	70.65
LAMPUNG	2	0.200032	-0.05438	-0.4760555	-0.17452	-0.15737	0.158617	-0.04391	-0.07555	-0.33855	72.02
DKI JAKARTA	0	0.499201	0.294244	1.0982153	1.402713	0.380063	0.298922	0.132814	0.239914	0.341256	77.67
JAWA BARAT	0	0.225541	-0.0375	-0.10031061	-0.27548	0.002049	0.118123	-0.06808	-0.00415	0.49775	73.34
JAWA TENGAH	1	-0.53864	0.072779	-0.39650568	-1.18475	-0.00879	-3.34553	-0.00563	-0.0394	0.025324	67.56
DI YOGYA	1	0.508485	0.034989	0.340477	0.265698	0.020533	-3.0429	-0.17284	0.088556	0.115681	71.14
JAWA TIMUR	2	0.06426	-0.08567	-1.0101215	-0.94568	-0.0576	0.050973	-0.15073	-0.06531	0.359153	71.14
BANTEN	2	0.07224	-0.39842	-1.0393312	-0.1532	0.074785	0.09938	-0.21814	-0.03623	-0.00139	71.38
BALI	0	0.66559	-0.07583	1.5194385	0.158591	0.090098	0.347438	0.210376	0.258025	0.293991	76.45
NUSA TENGGARA	2	-2.48124	-0.44546	-0.4487205	-1.06701	-0.12665	0.108841	-0.12152	0.06561	-0.35443	68.11
KALIMANTAN	2	0.265338	-0.06634	-0.30994222	-0.20193	-0.09781	0.320106	-0.04288	-0.04889	-0.3891	72.41

3 Clusters' SHAP Values

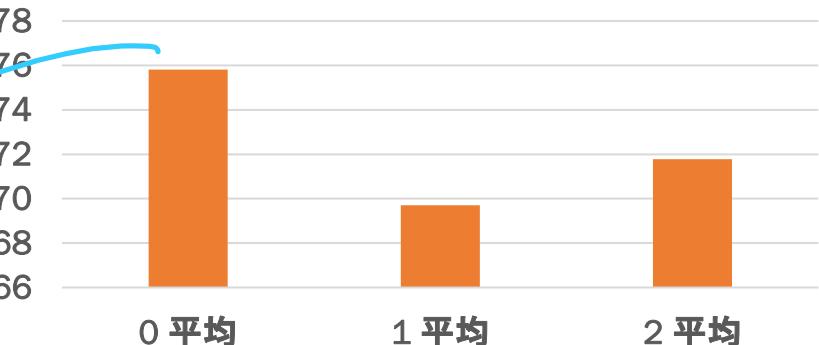
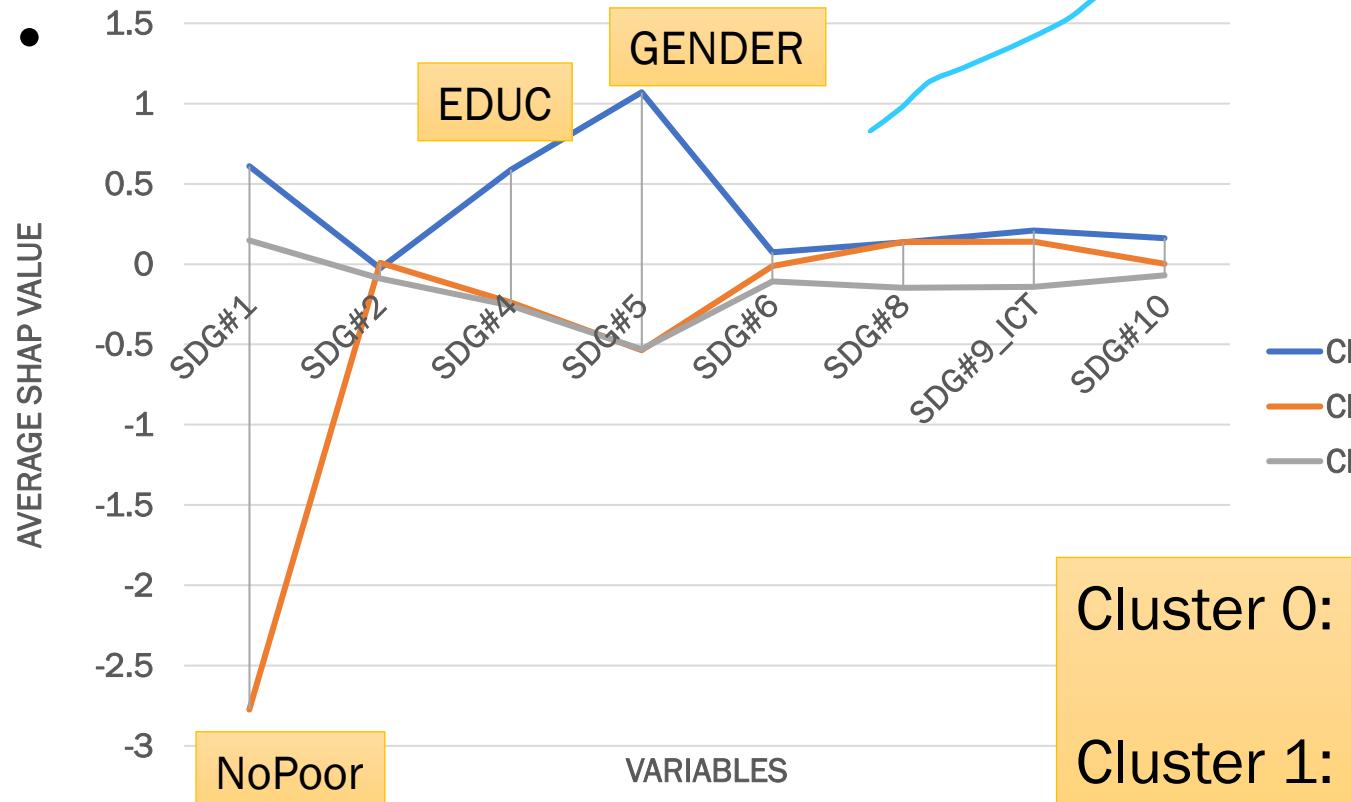
-



Cluster Average of Target Values

Characteristics of 3 Clusters

-

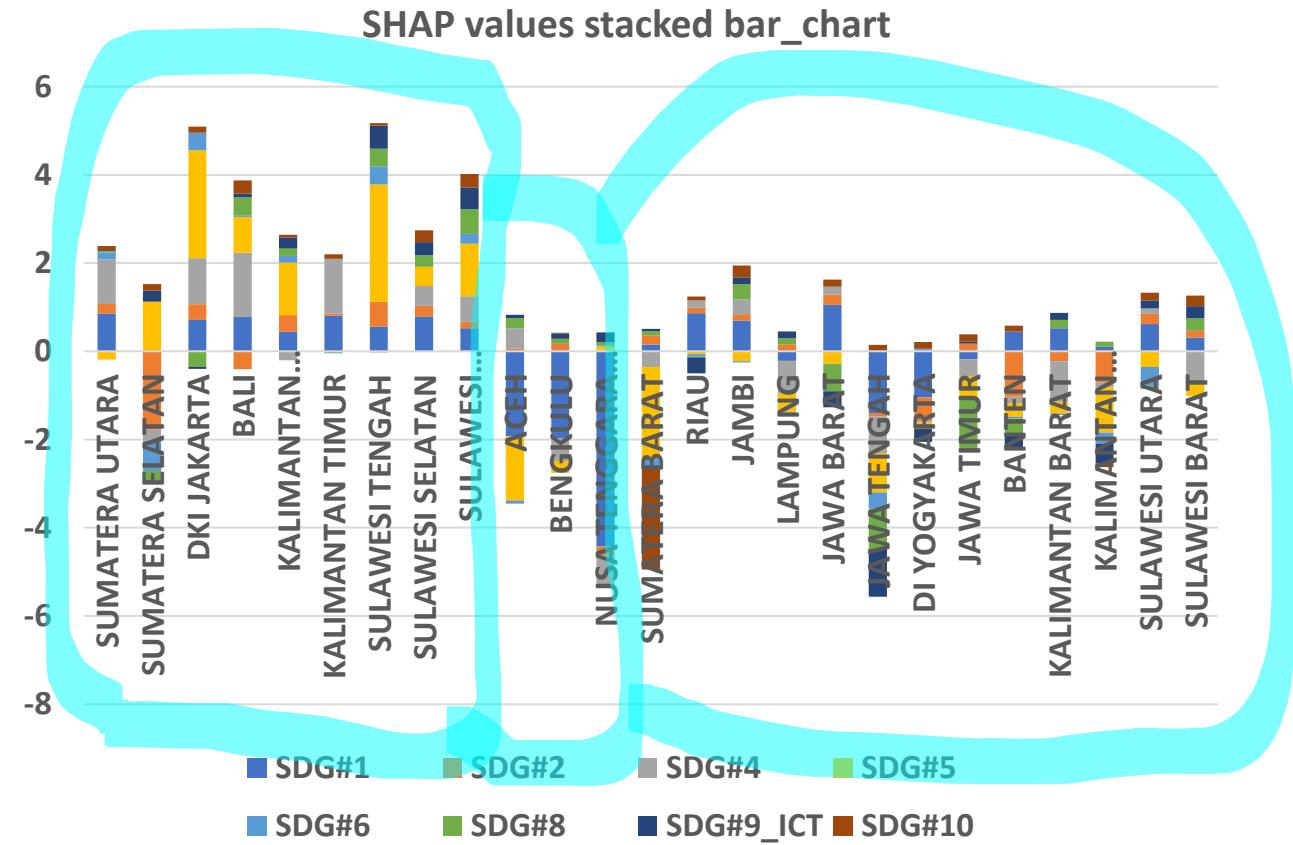


Cluster 0: GENDER score, and
EDUCATION score

Cluster 1: Poverty is the negative factor

Contents

1. Research Objective
2. Data Selection
3. Regression: XGBOOST
4. SHAP
5. Clustering by SHAP Values
6. Conclusion



Conclusions

- SDG#3 well-being is target
- Dominant factors for well-being
- XGBoost and SHAP
 - 1. SDG#5 (gender) 0.76
 - 2. SDG#1 (NoPoor) 0.68
 - 3. SDG#4 (Education) 0.66
- Clustering by SHAP
 - High well-being cluster: high gender_SHAP
 - Low well-being cluster's problem: poverty

