

離散音声トークン生成に基づく感情 合成音声のための多目的知覚評価値 を活用したdecoding戦略

山内一輝，中田亘，齋藤佑樹，猿渡洋

東京大学 情報理工学系研究科

● 背景

- 離散音声トークン生成に基づくテキスト音声合成手法
- 従来の decoding 戦略

● 関連研究

- BOK-PRP: 知覚評価値予測に基づく best-of- K 戦略

● 提案手法

- 感情音声合成のための多目的知覚評価値に基づく BOK-PRP
- 合成音声の自然性と感情強度のトレードオフを制御・改善

● 実験的評価

● まとめ

● 背景

- 離散音声トークン生成に基づくテキスト音声合成手法
- 従来の decoding 戦略

● 関連研究

- BOK-PRP: 知覚評価値予測に基づく best-of- K 戦略

● 提案手法

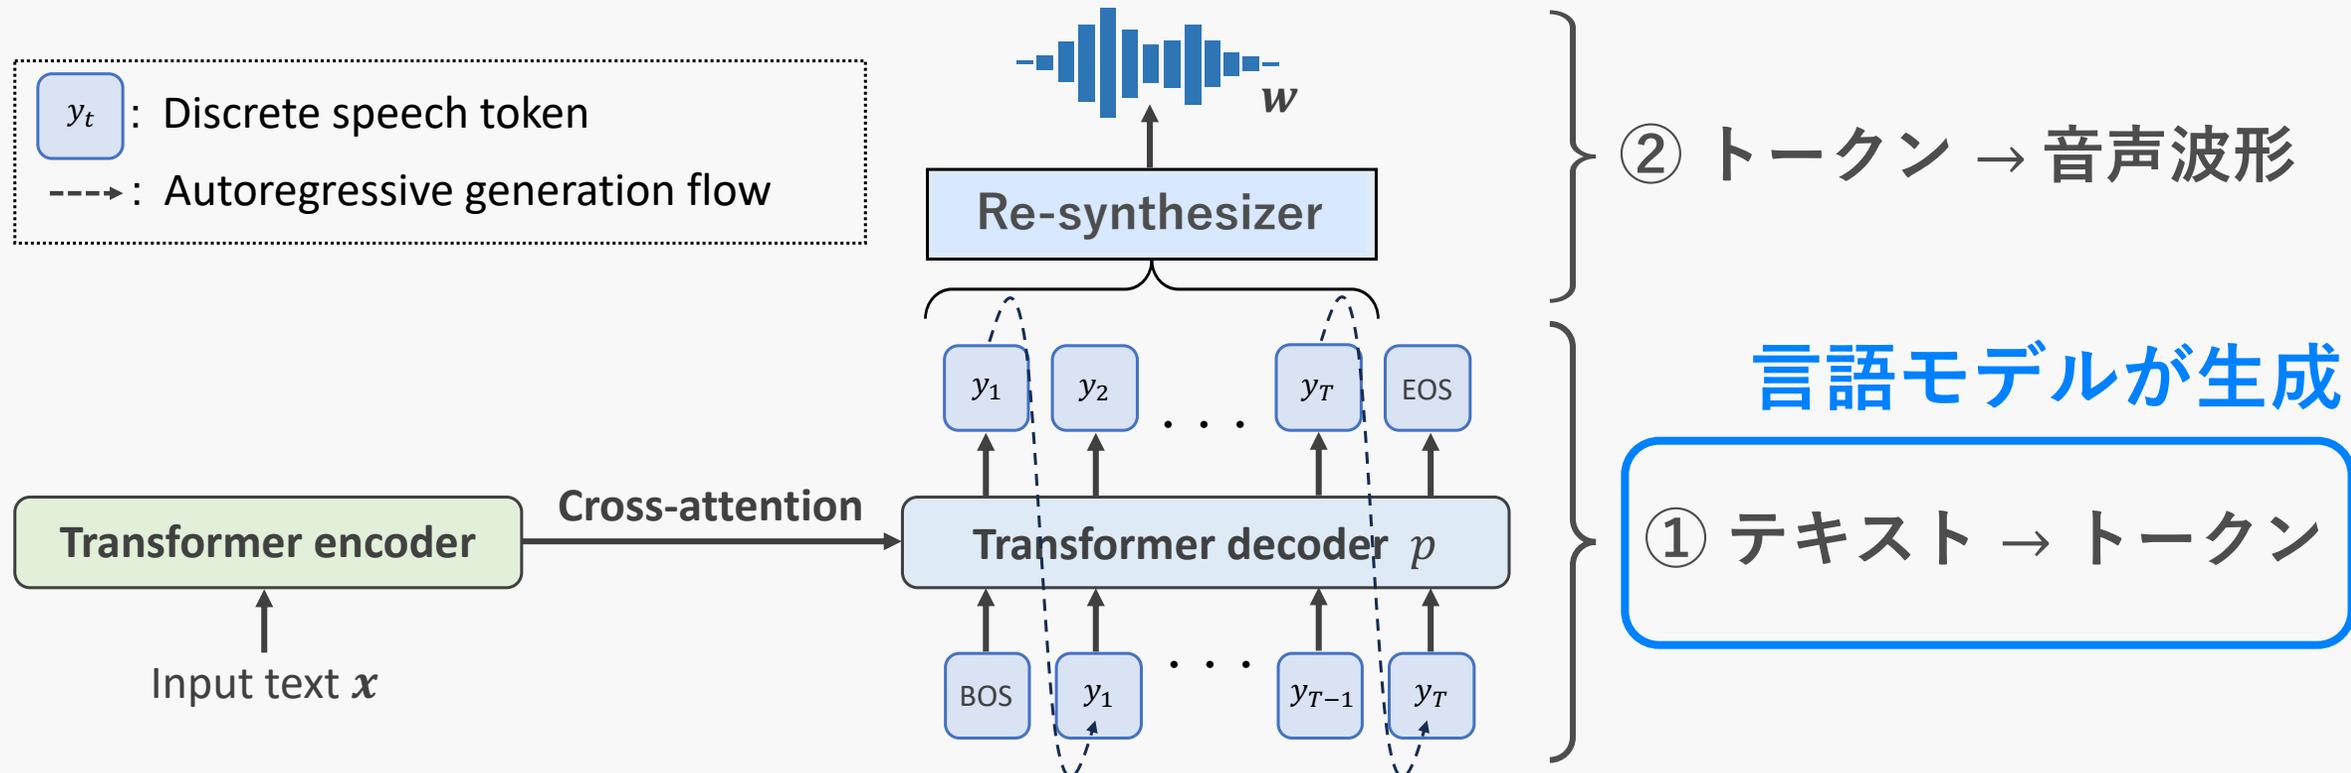
- 感情音声合成のための多目的知覚評価値に基づく BOK-PRP
- 合成音声の自然性と感情強度のトレードオフを制御・改善

● 実験的評価

● まとめ

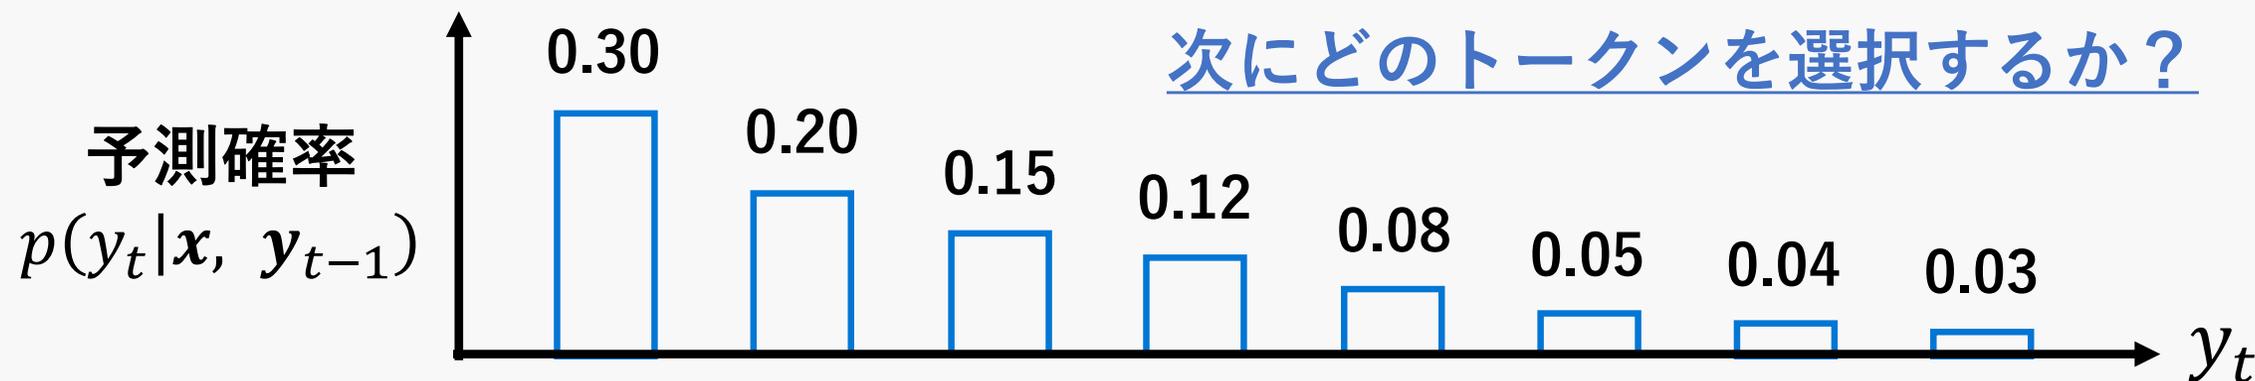
言語モデル (LM) に基づくテキスト音声合成 (TTS)

- 言語モデルにより離散音声トークンを自己回帰的に生成
 - 離散音声トークン: 音声特徴量を量子化することで得られる離散潜在表現



Decoding 戦略

- Decoding: 言語モデルによってモデル化された各トークンの生起確率分布に基づき, 次に出力するトークンを選択するプロセス



- Greedy decoding

- 予測確率が最も高いトークンを次の出力トークンとして選択
- 出力が**同じトークンの繰り返しに陥る**問題が生じる



従来のサンプリングを伴う decoding 戦略

- **Decoding にサンプリングを導入**
 - 代表例: top- k [A. Fan+2018] / top- p サンプリング[A. Holtzman+2020]
 - トークンを予測確率分布に基づいて確率的に選択
 - 繰り返し生成問題を効果的に対処
- **利点: サンプリングベースの戦略により韻律の多様性が向上**
 - 言語モデルに基づく感情音声合成モデルに適用することで, **合成音声の感情表現が豊かになる** [Z. Ju+2024]
- **課題: サンプリングのランダム性により生成が不安定化**
 - 雑音など不適切な出力が生成される可能性があり, **合成音声の自然性が不安定になる**

- 背景

- 離散音声トークン生成に基づくテキスト音声合成手法
- 従来の decoding 戦略

- 関連研究

- BOK-PRP: 知覚評価値予測に基づく best-of- K 戦略

- 提案手法

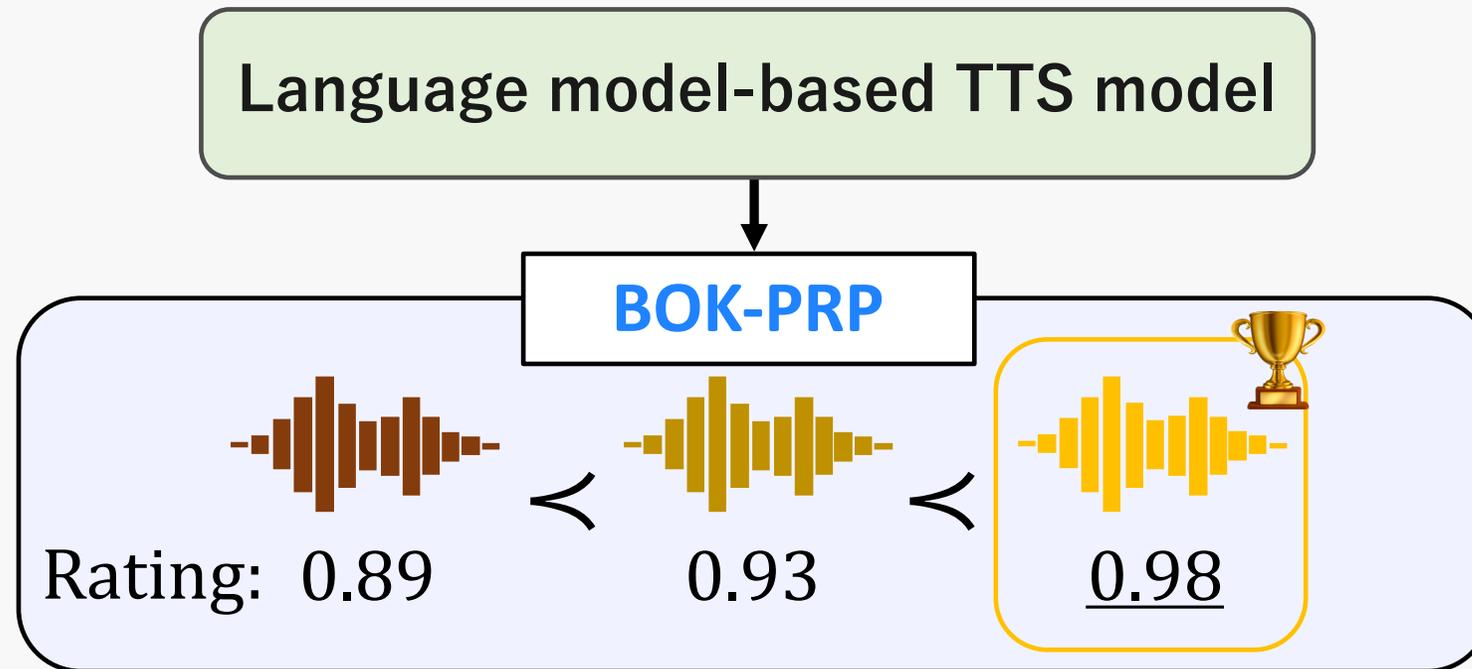
- 感情音声合成のための多目的知覚評価値に基づく BOK-PRP
- 合成音声の自然性と感情強度のトレードオフを制御・改善

- 実験的評価

- まとめ

BOK-PRP: Best-of- K (BOK) selection based on perceptual rating prediction (PRP) [K. Yamauchi+2024]

- サンプリングによって K 通りの音声を生成し，その中から最も“Rating”が高いサンプルを選択
 - 出力の多様性を保ちながら，不適切な出力を効果的にフィルタリング



自然性 MOS 予測に基づく BOK-PRP

- 自然性予測器 $r_{\text{nat}}(\mathbf{w})$:

$$r_{\text{nat}}(\mathbf{w}) = \frac{\text{UTMOS}(\mathbf{w}) - 1}{4}$$

- UTMOS [T. Saeki+22]: 広く用いられている自然性に関する 5 段階の Mean Opinion Score (MOS) 予測モデル
- $r_{\text{nat}}(\mathbf{w})$ の出力値は **0 (非常に不自然)** ~ **1 (非常に自然)** までの実数値

先行研究の課題

● 課題 1：実験条件が限定的

- 実験は**単一話者による読み上げ音声合成のみを対象**としている
- サンプルベースの戦略がより効果を発揮する、感情表現を伴う音声合成などの高度なタスクは検討されていない

● 課題 2：知覚評価の観点が限定的

- 知覚評価値として**自然性のみを検討**している
- 自然性以外(例：感情の表出度)の観点に基づく評価値を複合的に活用する手法は検討はされていない

- **背景**

- 離散音声トークン生成に基づくテキスト音声合成手法
- 従来の decoding 戦略

- **関連研究**

- BOK-PRP: 知覚評価値予測に基づく best-of- K 戦略

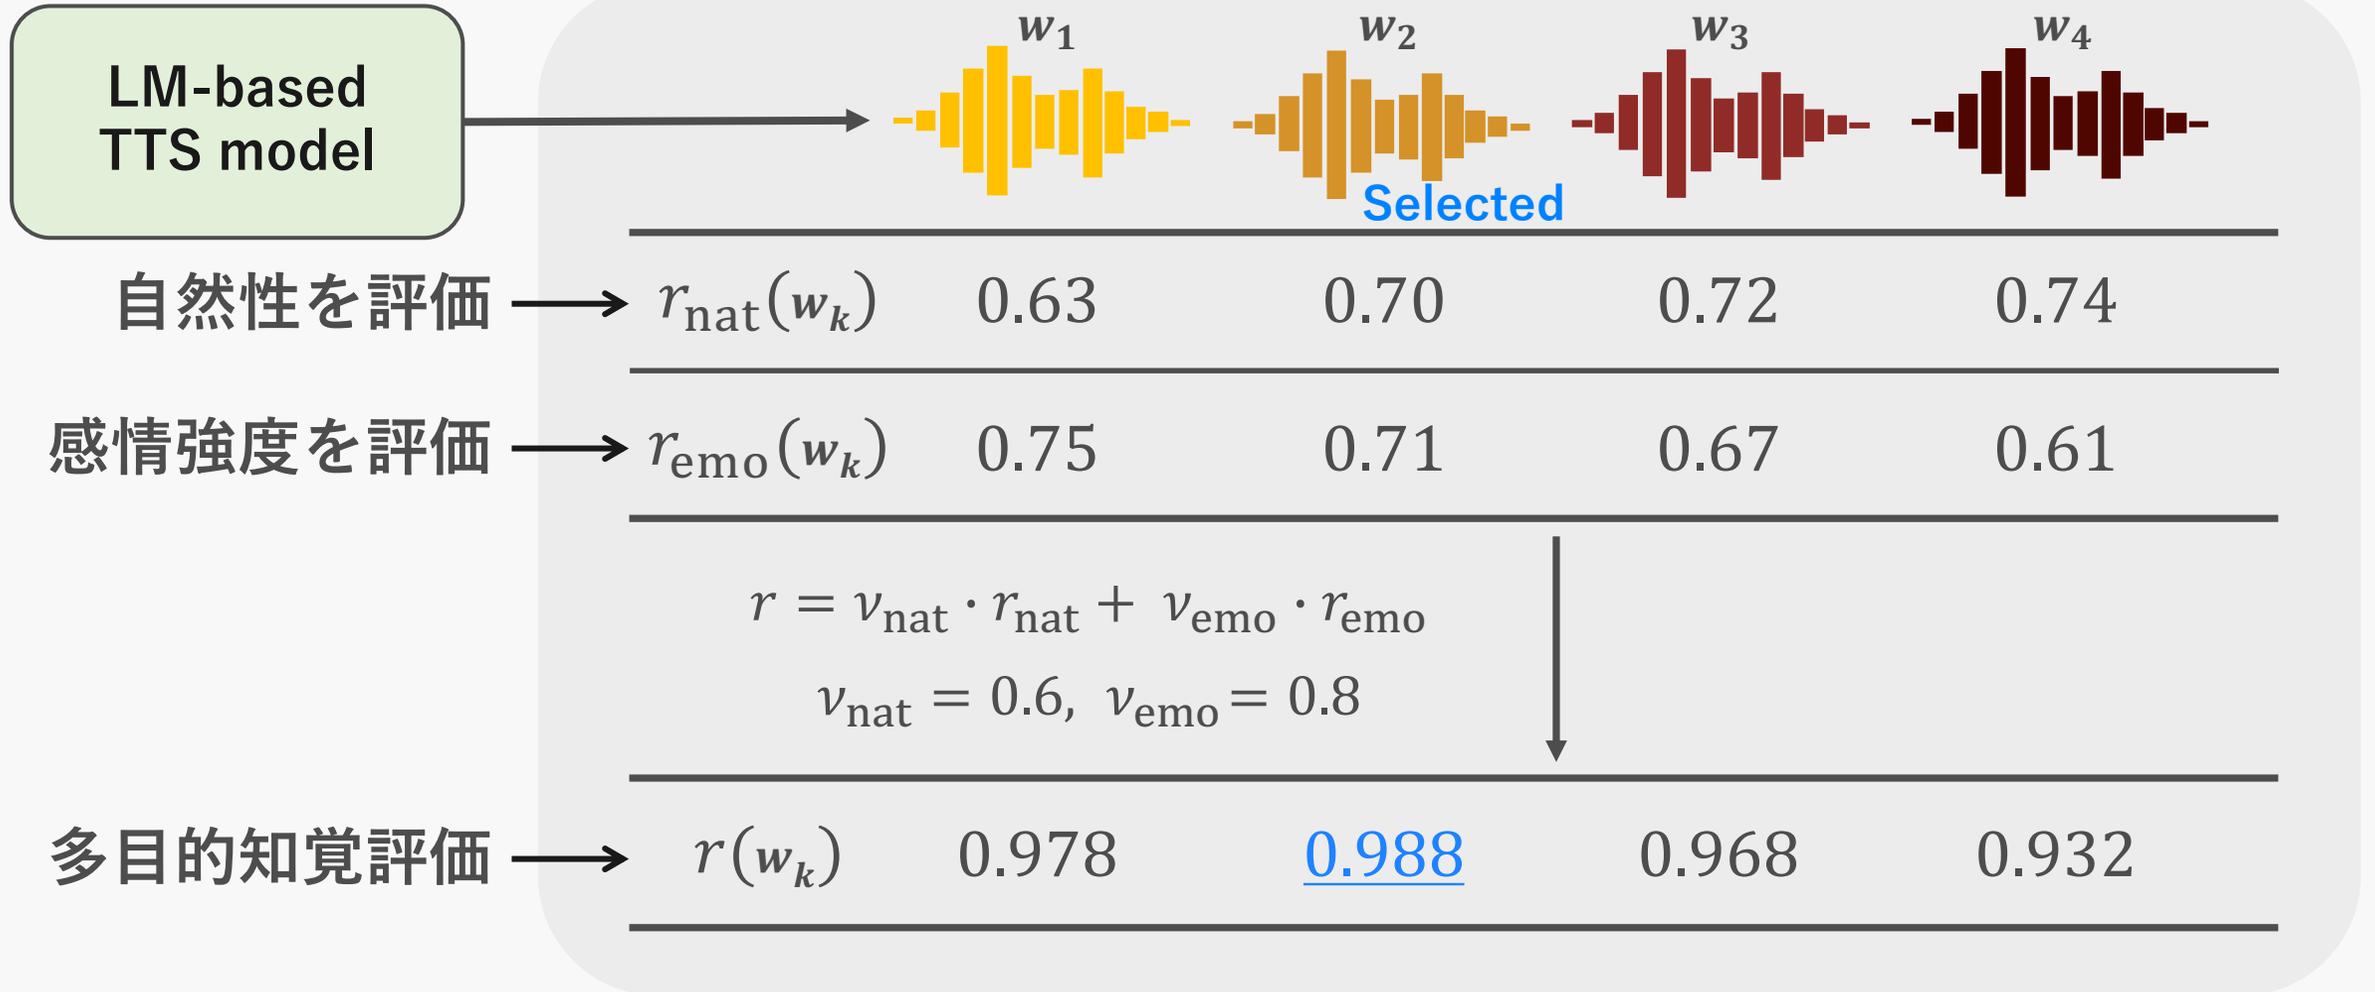
- **提案手法**

- 感情音声合成のための**多目的知覚評価値**に基づく BOK-PRP
- 合成音声の**自然性と感情強度のトレードオフ**を制御・改善

- **実験的評価**

- **まとめ**

多目的知覚評価に基づく BOK-PRP



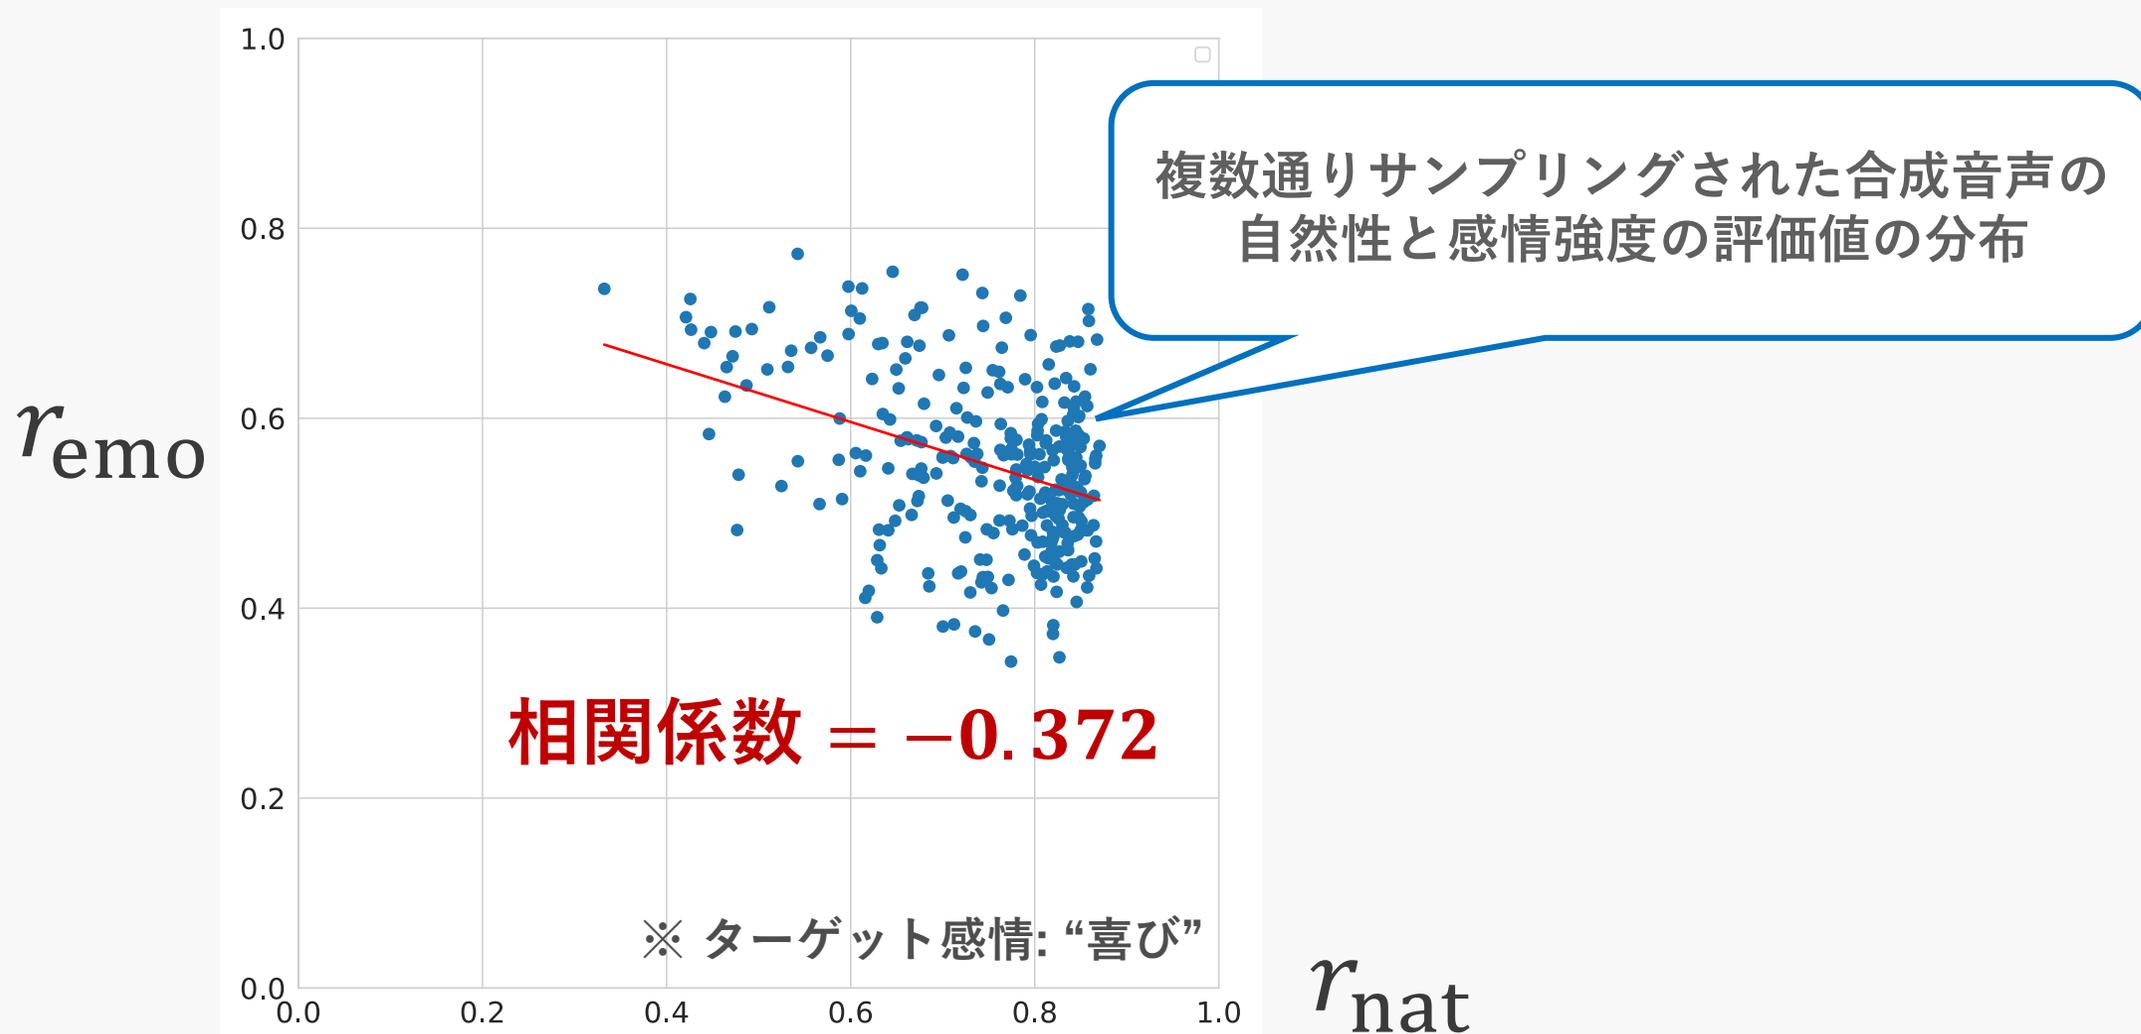
感情の表現力を評価するための感情強度予測器

- 感情強度予測器 $r_{\text{emo}}(\mathbf{w})$:

$$r_{\text{emo}}(\mathbf{w}) = \begin{cases} (\text{arousal}(\mathbf{w}) + (1 - \text{valence}(\mathbf{w}))) / 2 & \text{if ターゲット感情が "怒り"} \\ (\text{arousal}(\mathbf{w}) + \text{valence}(\mathbf{w})) / 2 & \text{if ターゲット感情が "喜び"} \\ ((1 - \text{arousal}(\mathbf{w})) + (1 - \text{valence}(\mathbf{w}))) / 2 & \text{if ターゲット感情が "悲しみ"} \end{cases}$$

- 事前学習済みの次元感情認識モデル [L. Goncalves+24] モデルを活用
 - 覚醒度 (arousal), 支配性 (dominance), 感情価 (valence) を 0 (低い) ~ 1 (高い) の範囲の実数値で予測
- ターゲット感情: 怒り (angry), 喜び (happy), 悲しみ (sad)
- $r_{\text{emo}}(\mathbf{w})$ の出力値は **0 (非常に弱い)** ~ **1 (非常に強い)** までの実数値

自然性と感情強度にトレードオフが存在



多目的知覚評価値

- 多目的知覚評価値予測器 $r(\mathbf{w})$:

$$r(\mathbf{w}) = v_{\text{nat}} \cdot r_{\text{nat}}(\mathbf{w}) + v_{\text{emo}} \cdot r_{\text{emo}}(\mathbf{w}),$$

where $v_{\text{nat}}, v_{\text{emo}} \in \mathbb{R}$, $v_{\text{nat}}^2 + v_{\text{emo}}^2 = 1$

- 合成音声の**自然性と感情強度にトレードオフが存在**することに着目
- 重み係数 v_{nat} と v_{emo} を手動で調整することで、decoding 時に**自然性と感情強度のどちらをより重視するかを制御可能**

- **背景**

- 離散音声トークン生成に基づくテキスト音声合成手法
- 従来の decoding 戦略

- **関連研究**

- BOK-PRP: 知覚評価値予測に基づく best-of- K 戦略

- **提案手法**

- 感情音声合成のための**多目的知覚評価値**に基づく BOK-PRP
- 合成音声の**自然性と感情強度のトレードオフ**を制御・改善

- **実験的評価**

- **まとめ**

実験条件

- **言語モデルに基づく感情 TTS モデル:**
 - Cosyvoice-300M-Instruct model [Z. Du+24] (事前学習済み)
- **比較評価のための参照音声:**
 - Emotional Speech Dataset (ESD)-English [K. Zhou+22] のテストセット
 - 10名の話者 × 3感情 (怒り, 喜び, 悲しみ) × 各30発話 (計900発話)
- **主観評価指標:** ※ 250 人の参加者が, それぞれ 24 サンプルを評価
 - **自然性 MOS**
 - 合成音声の自然性を **1 (非常に不自然)** ~ **5 (非常に自然)** の 5 段階で評価
 - **感情強度 MOS**
 - 合成音声の感情強度を **1 (非常に弱い)** ~ **5 (非常に強い)** の 5 段階で評価

実験条件

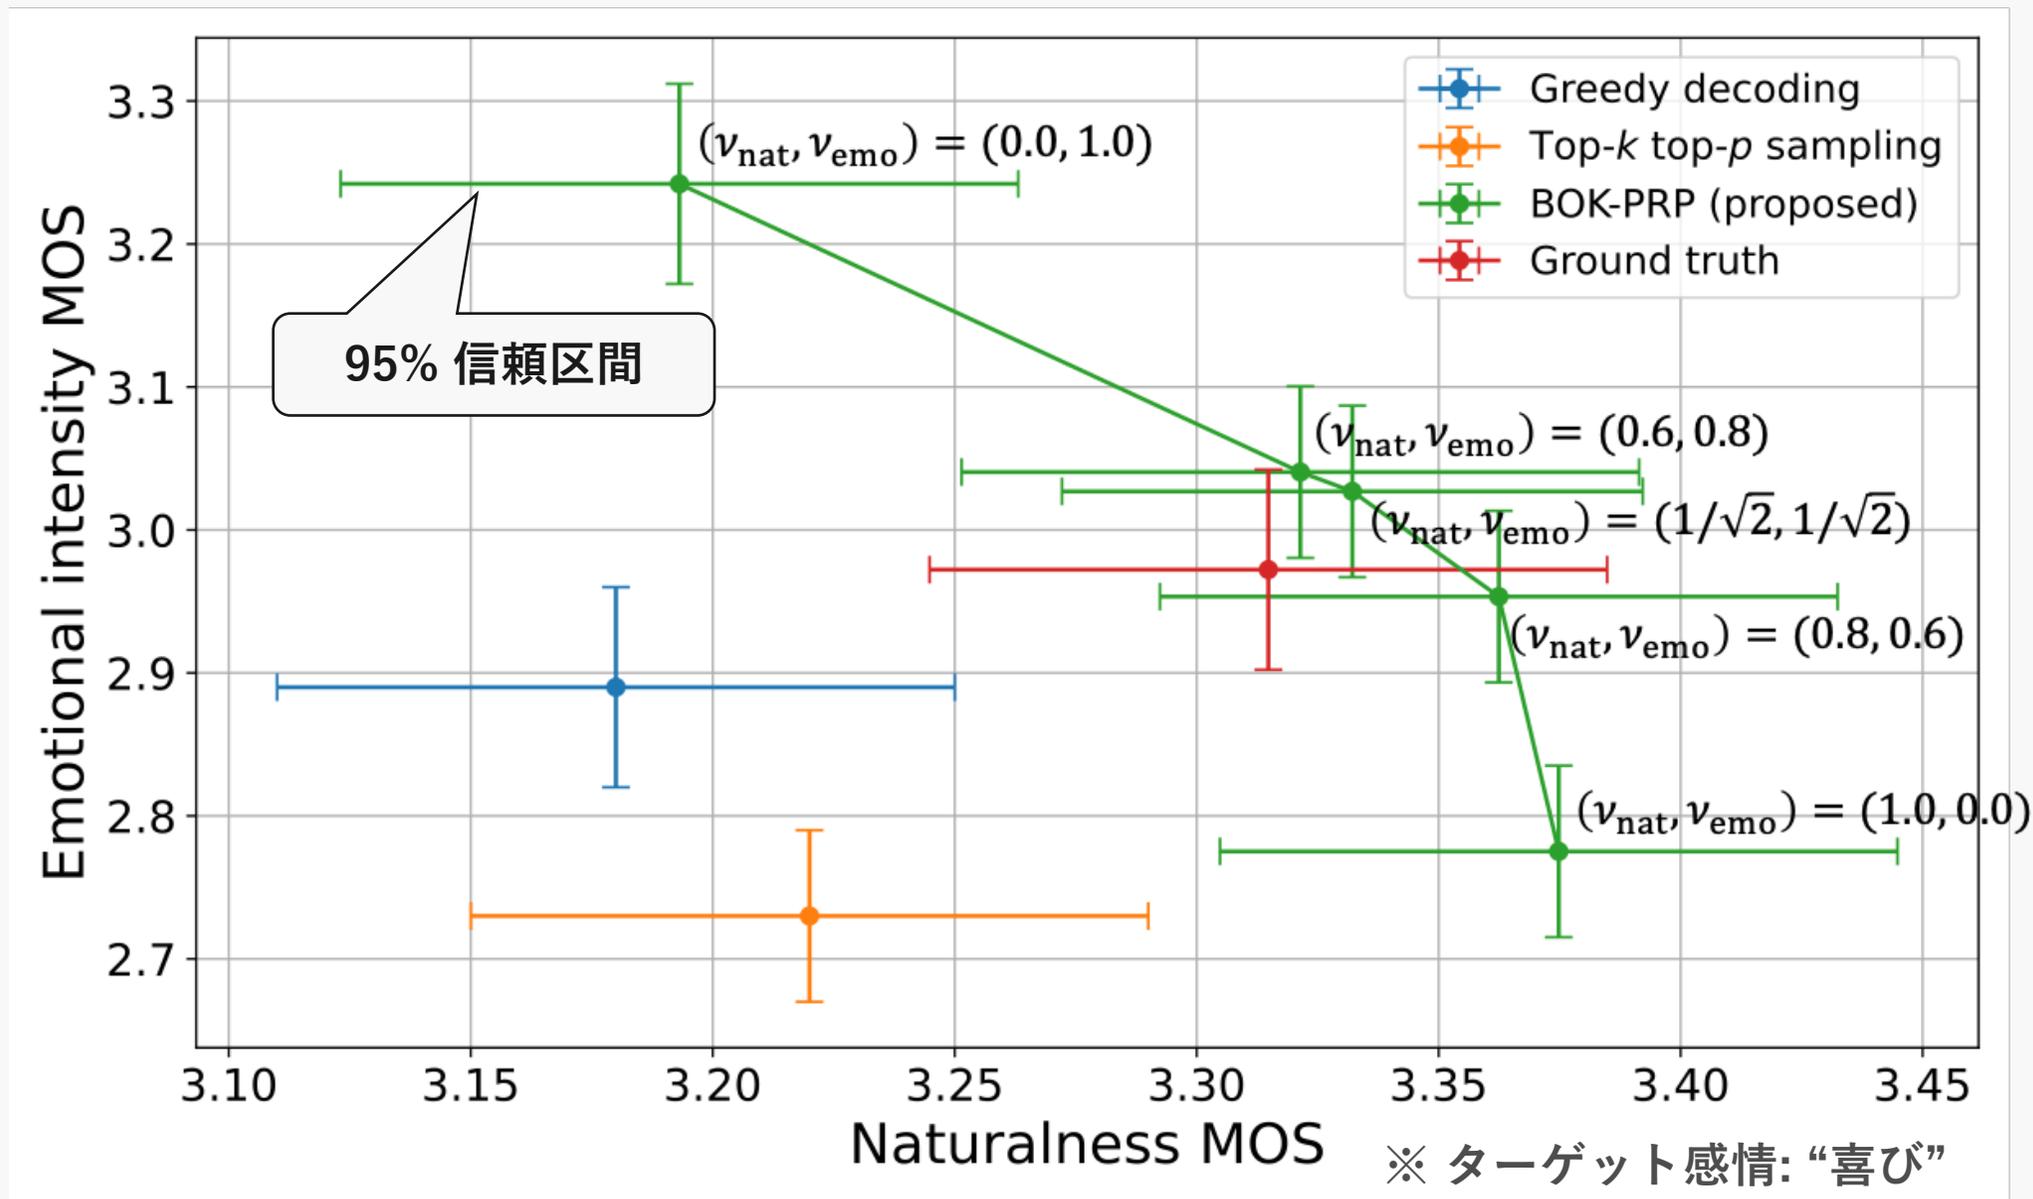
- 比較手法:

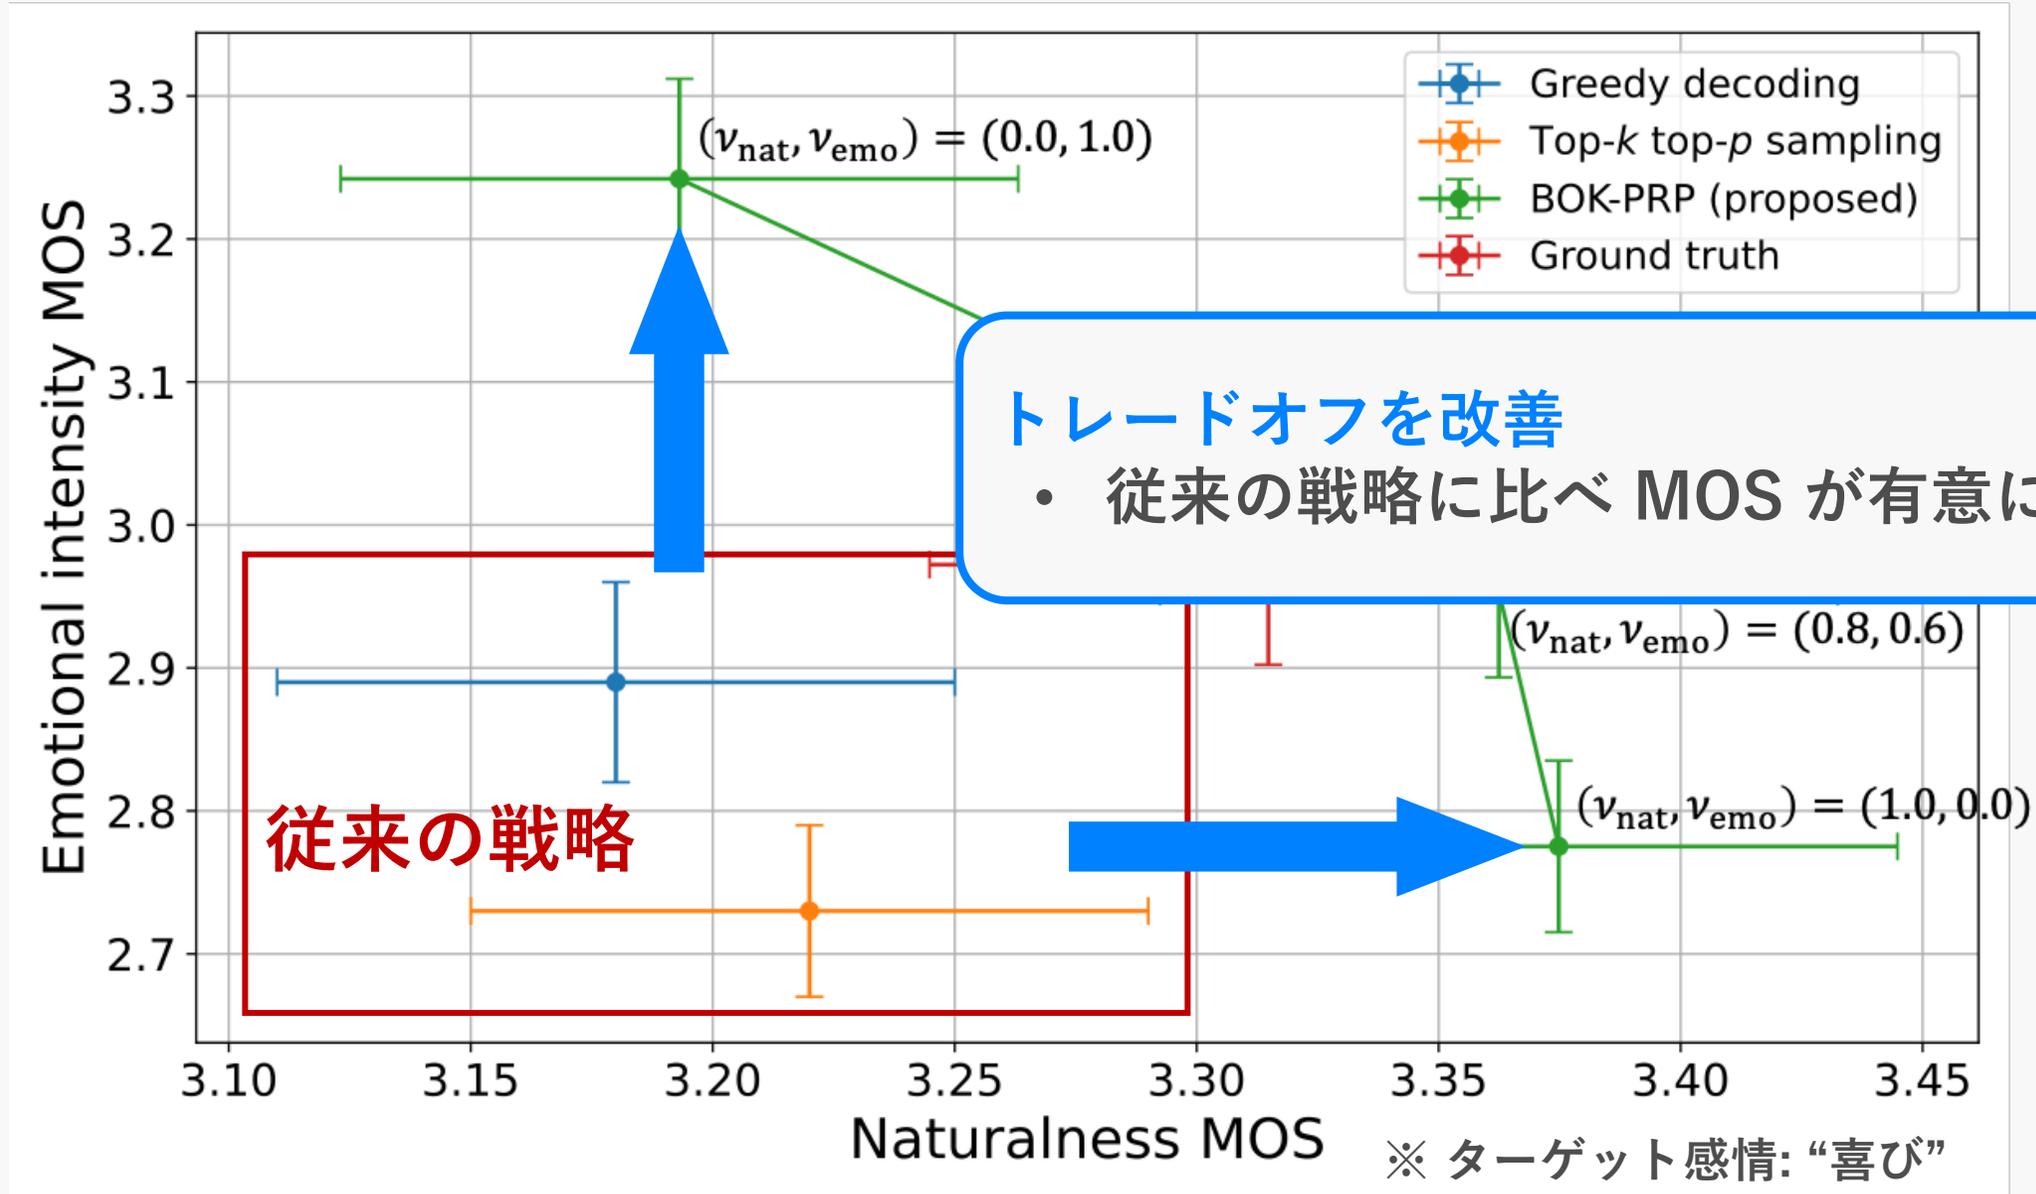
- Greedy decoding
- Top- k top- p sampling
- 多目的知覚評価値に基づく BOK-PRP (Proposed)

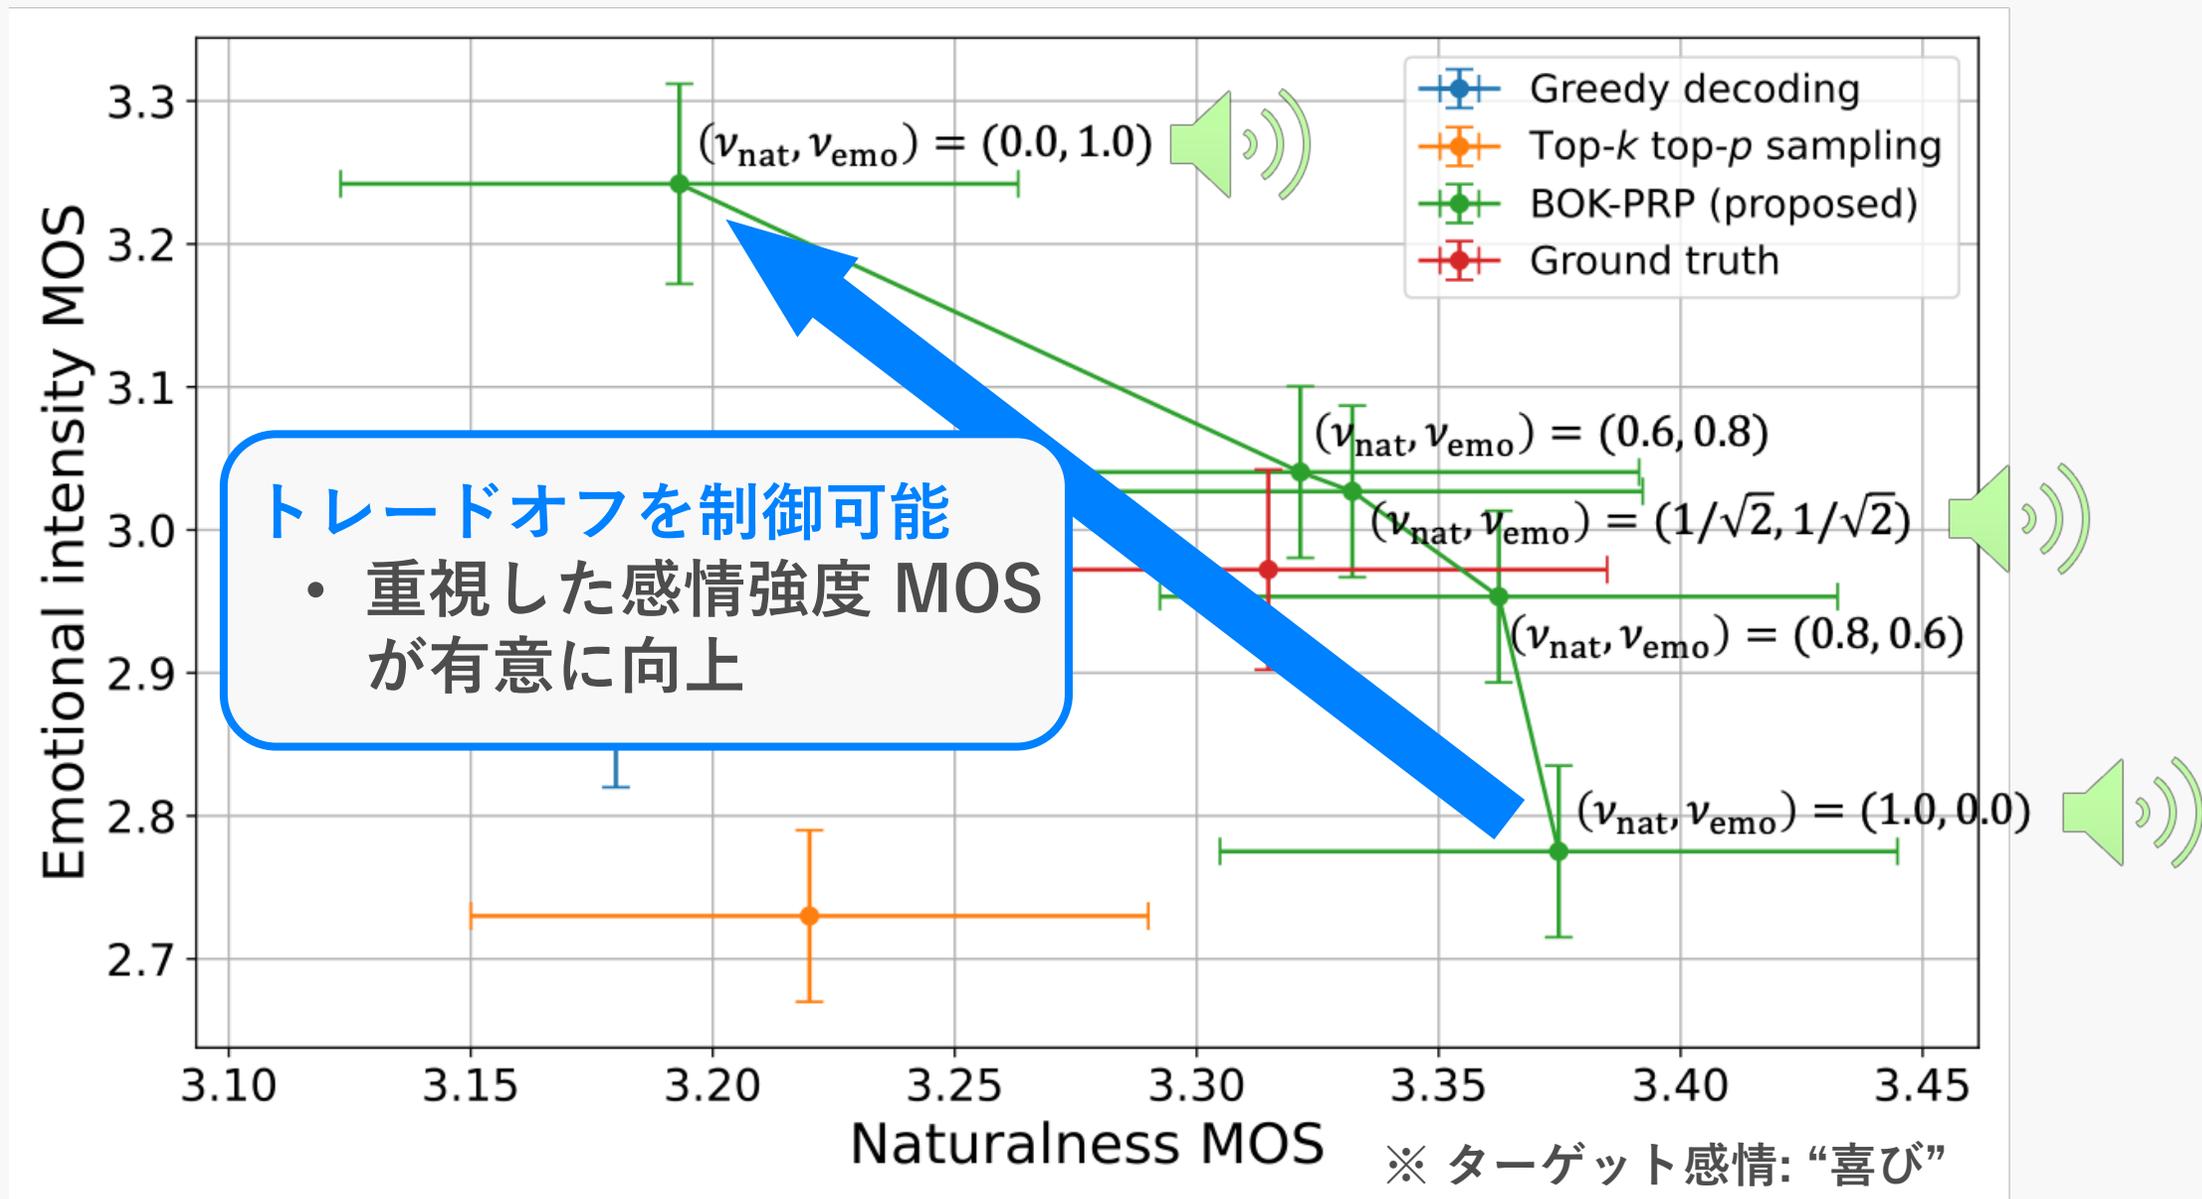
- BOK-PRP の設定

- サンプルサイズ K の値は 10 に設定
- 多目的知覚評価値の重み係数は以下の 5 通りの組み合わせを比較:

$$(v_{\text{nat}}, v_{\text{emo}}) = (1.0, 0.0), (0.8, 0.6), \left(\frac{1}{\sqrt{2}}, \frac{1}{\sqrt{2}}\right), (0.6, 0.8), (0.0, 1.0)$$







- 背景

- 離散音声トークン生成に基づくテキスト音声合成手法
- 従来の decoding 戦略

- 関連研究

- BOK-PRP: 知覚評価値予測に基づく best-of- K 戦略

- 提案手法

- 感情音声合成のための多目的知覚評価値に基づく BOK-PRP
- 合成音声の自然性と感情強度のトレードオフを制御・改善

- 実験的評価

- まとめ

BOK-PRP に多目的知覚評価を新たに導入

● 本研究の目的:

- 合成音声の自然性を保ちながら、多様で豊かな感情表現を生成可能な decoding 戦略の開発

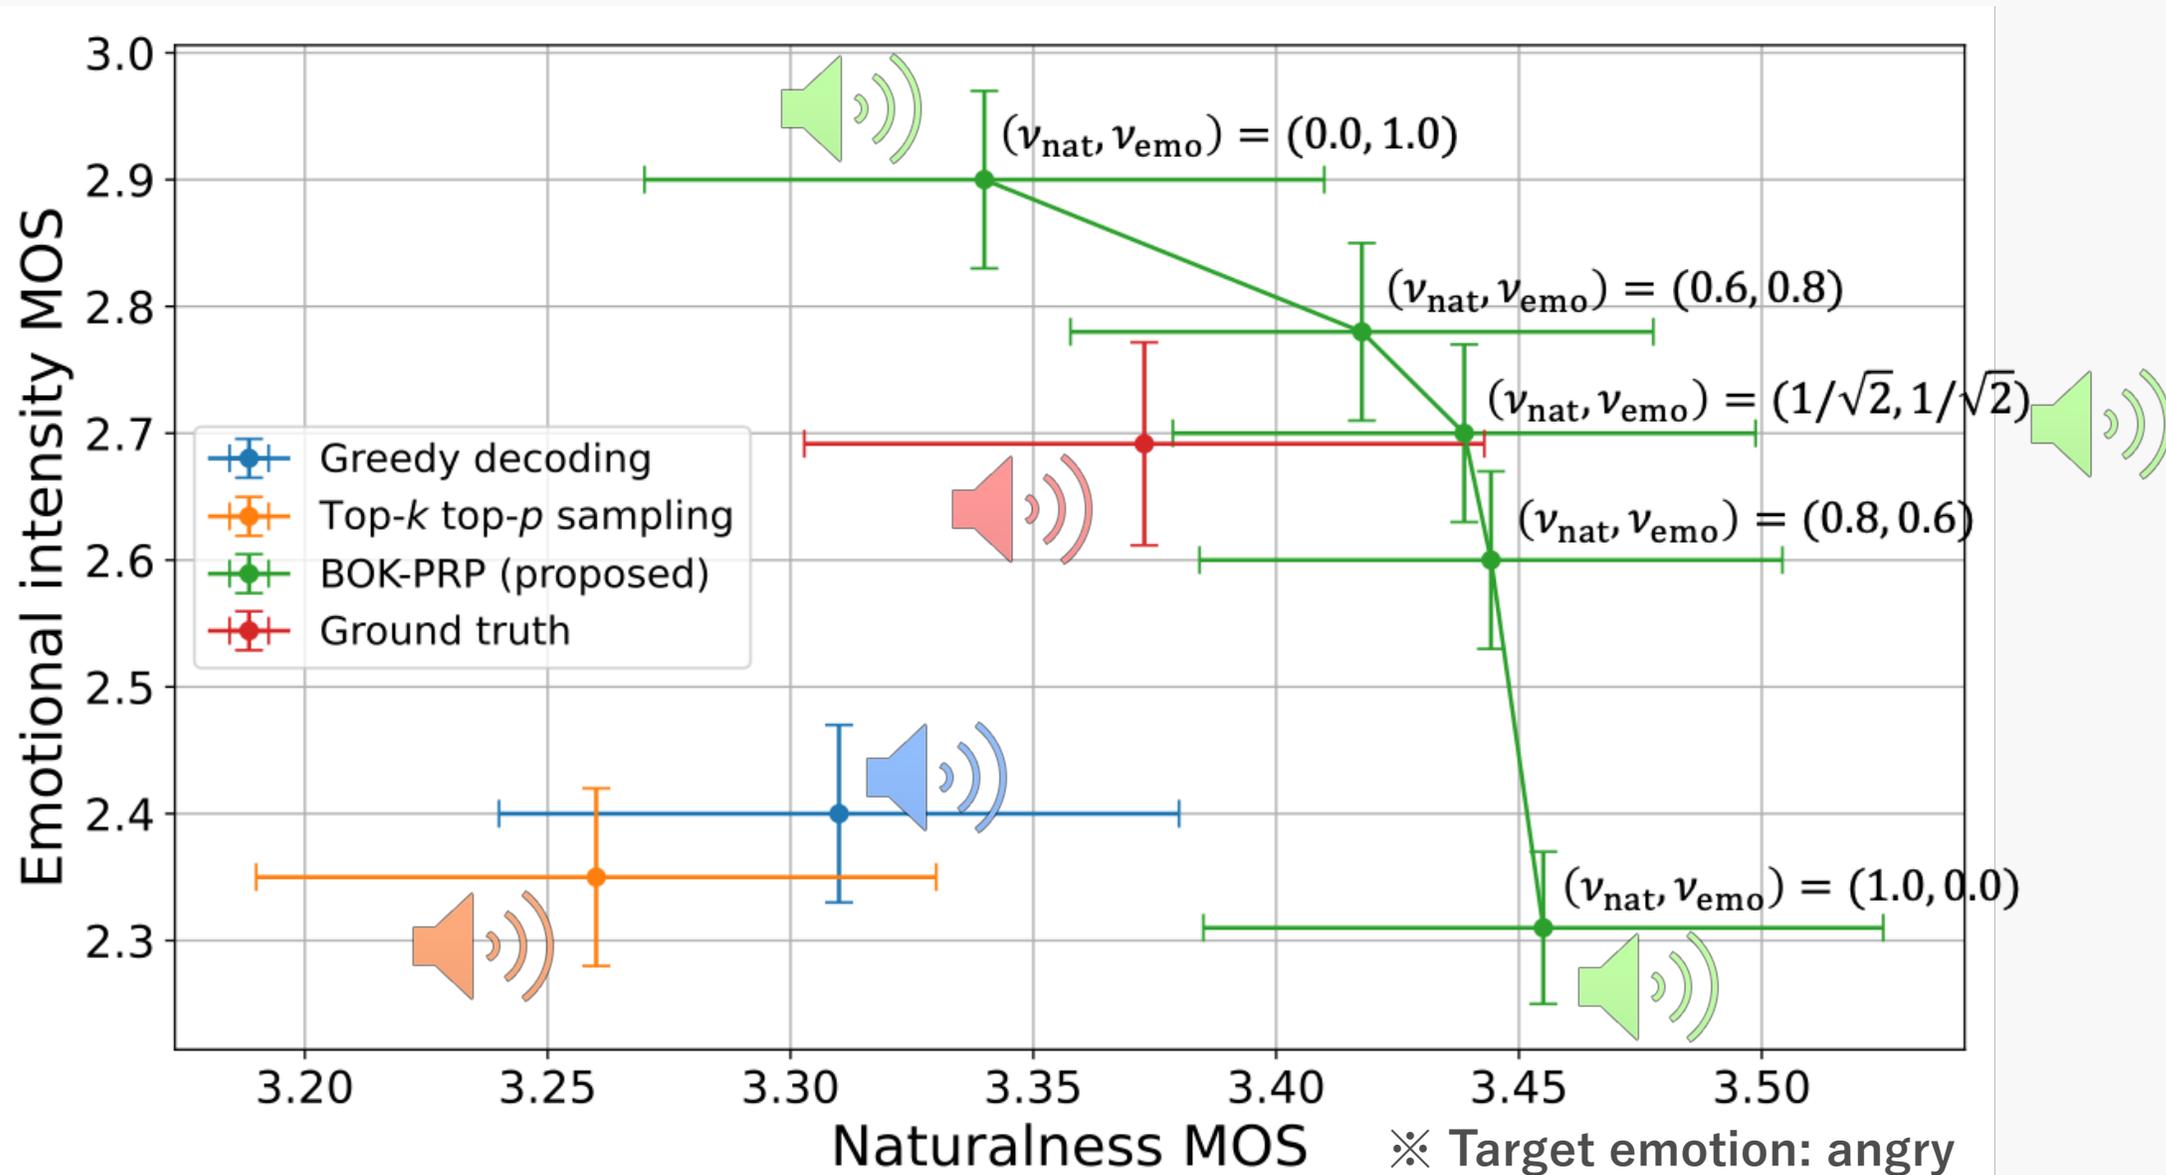
● 提案手法:

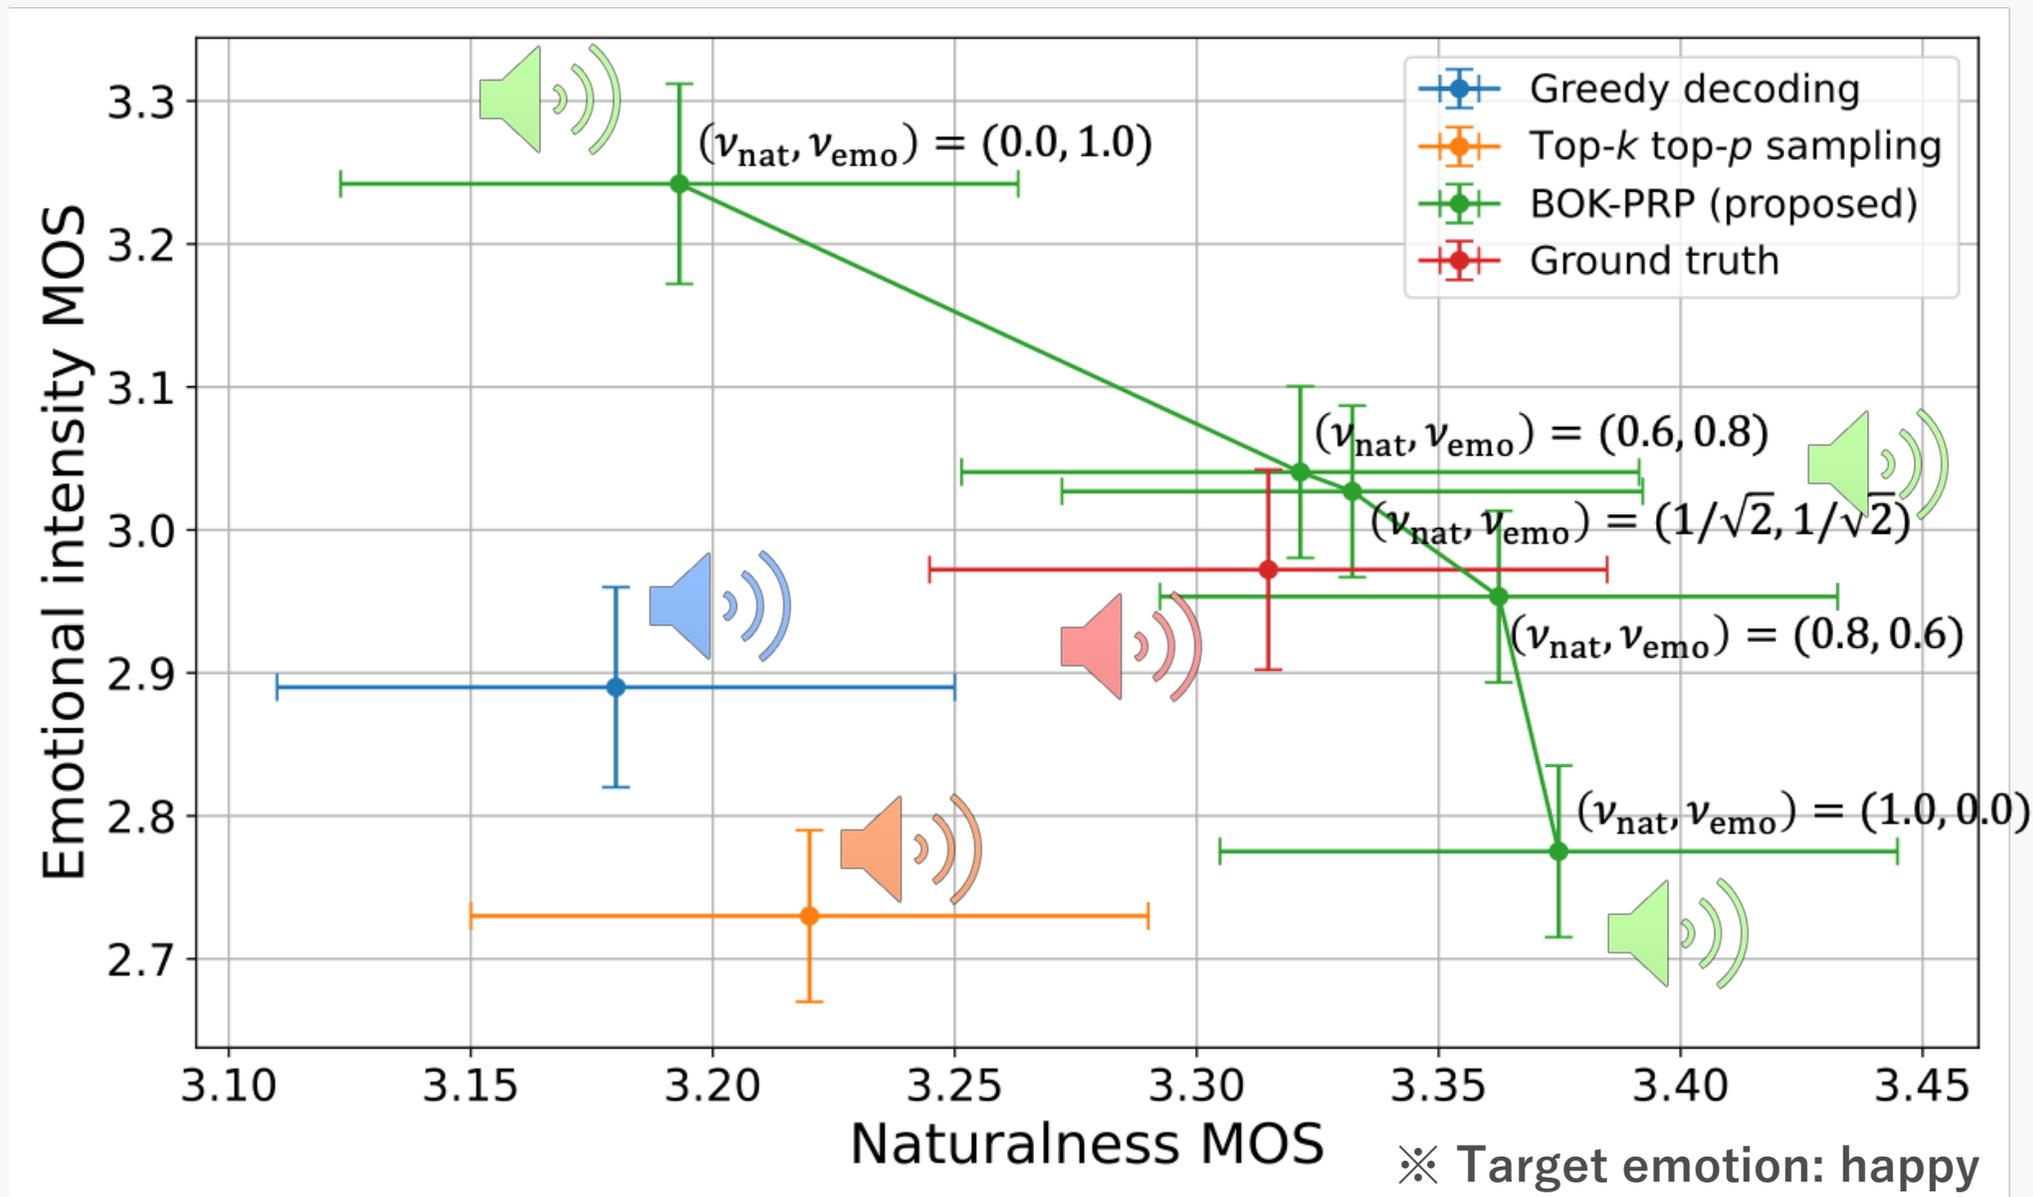
- 感情音声合成のための多目的知覚評価値に基づく BOK-PRP
- 合成音声の自然性と感情強度のトレードオフを制御・改善

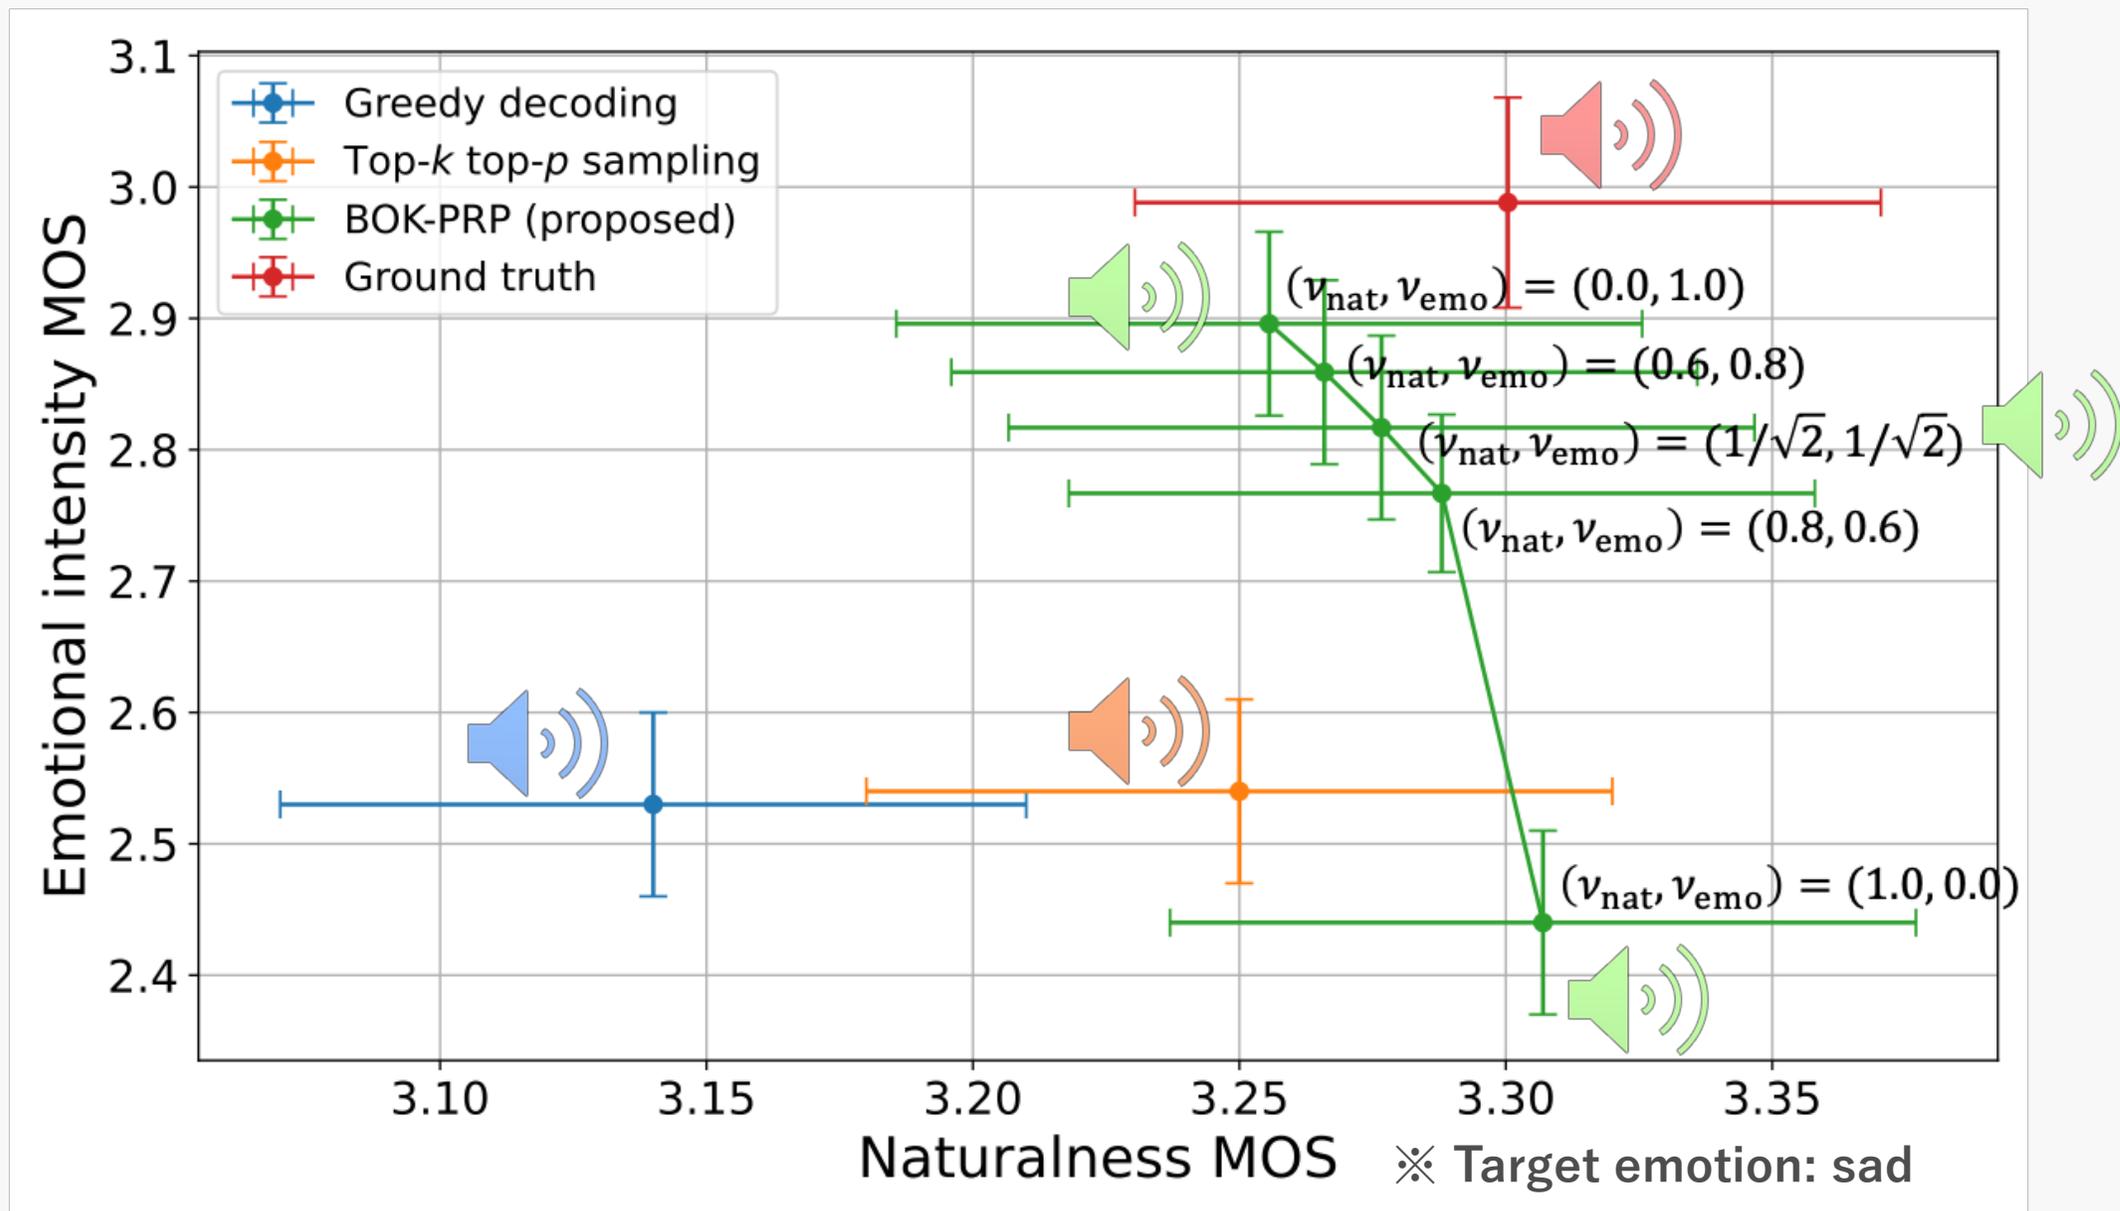
● 今後の展望:

- BOK-PRP を 韻律的な自然性 や 音声対話における流暢性 など、より複雑で多様な知覚評価に拡張

Appendix







K	MOS (\uparrow)	UTMOS (\uparrow)
2	3.72 ± 0.08	4.40
4	3.74 ± 0.08	4.43
8	3.83 ± 0.07	4.43
16	3.79 ± 0.07	4.45
32	3.65 ± 0.08	4.46

Over-optimization:

Excessively large K degrades naturalness

Listening Evaluation Test

Please read the following instructions carefully.

Listen to the speech with anger and rate **the naturalness of the speech** (does it sound human-like and natural?) and **the intensity of anger** on a 5-point scale, respectively.

When you click [start] button, the audio starts to play.

Please perform the evaluation in a quiet environment and with headphones.

Do not use your browser's "back" or "reload" buttons during the test.

Select [1] to [5] (you can play it again with the [replay] button).

Question 1/24

Naturalness

1: Very Poor

2: Poor

3: Fair

4: Good

5: Very Good

Intensity of anger

1: Very Weak

2: Weak

3: Moderate

4: Strong

5: Very Strong

user:beethoven1166